



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

X-RAY GÖRÜNTÜLERİNDEN GİZLENMİŞ
ELEKTRONİK DEVRELERİN DERİN
ÖĞRENME YÖNTEMLERİYLE TESPİTİ

Gökhan SEYFİ

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Aralık-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Gökhan SEYFİ tarafından hazırlanan “X-Ray Görüntülerinden Gizlenmiş Elektronik Devrelerin Derin Öğrenme Yöntemleriyle Tespiti” adlı tez çalışması 31/12/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Mehmet HACIBEYOĞLU

.....

Danışman

Prof. Dr. Mustafa Servet KIRAN

.....

Üye

Prof. Dr. Erkan ÜLKER

.....

Üye

Prof. Dr. İsmail BABAOĞLU

.....

Üye

Doç. Dr. Ali YAŞAR

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

Bu tez çalışması TÜBİTAK 1001 Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı 124E024 numaralı proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Gökhan SEYFİ

Tarih: 16/01/2024

ÖZET

DOKTORA TEZİ

X-RAY GÖRÜNTÜLERİNDEN GİZLENMİŞ ELEKTRONİK DEVRELERİN DERİN ÖĞRENME YÖNTEMLERİYLE TESPİTİ

Gökhan SEYFİ

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mustafa Servet KIRAN

Yıl, 2024 Sayfa 99

Jüri

Prof. Dr. Mehmet HACİBEYOĞLU
Prof. Dr. Mustafa Servet KIRAN
Prof. Dr. Erkan ÜLKER
Prof. Dr. İsmail BABAOĞLU
Doç. Dr. Ali YAŞAR

Kamu kurum ve kuruluşlarında vazgeçilmez olan güvenlik terör vb. eylemlere karşı en yüksek seviyeye çıkarılmaya çalışılır. Bunun için güvenlik görevlileri tarafından kullanılan X-ray görüntüleri üzerinden yasaklı maddelerin görevliler tarafından tespiti, zaman, iş gücü ve uzman eksiklikleri nedeniyle verimli olmayabilir. Bu ve benzer sebeplerden ötürü ilgili süreci otomatikleştirmek ve insan faktörünü ortadan kaldırmak için çeşitli yöntemler geliştirilmiştir. Derin öğrenme yöntemleri ile görüntü analizi ve nesne tanıma ise bu sorunları aşma potansiyeline sahiptir.

Tez çalışmasında, dizüstü bilgisayarlar gibi elektronik cihazlarda gizlenmiş patlayıcı devrelerinin tespiti konusu incelenmiştir. Bu problemi çözmek için hipotezler sunulmuş ve bu hipotezlere dayanarak derin öğrenme tabanlı çözüm yaklaşımları geliştirilmiştir. Problemi çözmek için ilk aşamada yeni ve özgün bir veri seti oluşturulmuş ve bu veri seti üzerinde sınıflandırma literatürdeki derin öğrenme modelleri kullanılarak gerçekleştirilmiştir. Yapılan deney çalışmaları sonuçları incelendiğinde veri seti boyutu ve karmaşıklığı nedeniyle çeşitli problemler ortaya çıktığı görülmüştür. İkinci aşamada elde edilen sınıflandırma başarılarının artırılması amacıyla derin öğrenme modelleri özellik haritalarını birleştirmeye yönelik bir yaklaşım geliştirilmiştir. Bu yaklaşımın, özellikle boyutun küçük ve karmaşıklığının yüksek olduğu veri setlerinde başarıyı artırımı için yol gösterici nitelikte olduğu düşünülmektedir.

Çalışmanın ilk aşamasında derin öğrenme alanında yaygın olarak kullanılan Evrişimsel Sinir Ağları tabanlı 11 farklı model sınıflandırma amacıyla tasarlanmıştır. Çalışmada yaşanan ilk zorluk veri setinin boyutunun küçük olması ve karmaşıklığı nedeniyle test esnasında yaşanmıştır. Test başarısı eğitim başarısına göre düşük olmuş ve yöntemler aşırı öğrenme yapmıştır. Bu durumu azaltmak ve başarıyı artırmak için daha kısa süre eğitime ihtiyaç duyan ve aşırı öğrenmeye dirençli bir sınıflandırıcı yöntem kullanılması hedeflenmiştir. Böylece RWN (Random Weight Network) tabanlı bir sınıflandırıcı içeren özellik füzyonu yöntemi önerilmiş, yapılan literatürdeki derin öğrenme yöntemlerine ait deneyler ve yalnızca sınıflandırıcının değiştirildiği yöntem ile kıyaslanmış patlayıcı tespitinde kullanılmıştır.

Çalışmanın son bölümünde RWN ve özellik füzyonu kullanılarak bir analiz yapılmıştır. Bu analiz, farklı ara katman ve hiper parametreler değerleri altında her bir yaklaşımın performansını ve etkinliğini değerlendirmeyi amaçlamıştır. Sonuç olarak geliştirilen özellik füzyonu yönteminin başarıya katkısı deney sonuçlarıyla gösterilmiştir.

Anahtar Kelimeler: CNN, Derin Öğrenme, RWN, Sonradan özellik füzyonu, Sınıflandırma, X-ray güvenlik görüntülemesi

ABSTRACT

PhD THESIS

DETECTION OF CONCEALED ELECTRONIC CIRCUITS IN X-RAY IMAGES USING DEEP LEARNING METHODS

Gökhan SEYFİ

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Prof. Dr. Mustafa Servet KIRAN

2024, 99 Pages

Jury

Prof. Dr. Mehmet HACIBEYOĞLU

Prof. Dr. Mustafa Servet KIRAN

Prof. Dr. Erkan ÜLKER

Prof. Dr. İsmail BABAOĞLU

Assoc. Prof. Dr. Ali YAŞAR

This thesis focuses on the detection of explosive circuits hidden in electronic devices, such as laptops, using X-ray imaging technologies, which are commonly used for security purposes in public institutions. The detection of prohibited items by security personnel through X-ray images may not be efficient due to issues such as time constraints, labor, and lack of expertise. Therefore, various methods have been developed to automate this process and eliminate human factors. Deep learning methods hold the potential to overcome these issues by automating image analysis and object recognition.

In the first phase of the study, an original dataset was created for detecting explosive circuits, and classification was performed using deep learning models on this dataset. However, due to the small size and high complexity of the dataset, various problems arose during the testing phase. To address these issues, in the second phase, a method was developed to improve classification performance by combining feature maps from deep learning models.

In particular, 11 different models based on Convolutional Neural Networks (CNN) were designed for classification purposes. The first challenge in the study was the small size of the dataset, which led to overfitting during testing, resulting in lower test performance compared to training performance. To mitigate this issue and improve performance, a classifier method that requires shorter training time and is resistant to overfitting was proposed. Thus, a feature fusion method with a Random Weight Network (RWN)-based classifier was introduced, and its performance was compared with the deep learning methods in the literature, as well as with a method where only the classifier was changed, for explosive detection.

In the final section of the study, an analysis was conducted using RWN and feature fusion. This analysis aimed to evaluate the performance and effectiveness of each approach under different intermediate layer and hyperparameter values. As a result, the contribution of the developed feature fusion method to success was demonstrated through experimental results.

Keywords: CNN, Deep Learning, RWN, Feature Fusion, Classification, X-ray Security Imaging.

ÖNSÖZ

Bu tez çalışması kapsamında dizüstü bilgisayarların içerisine gizlenebilecek tehlikeli materyalin derin öğrenme yöntemleriyle tespit edilmesine yönelik çalışmalar sürdürülmüştür. Doktora tezim, TÜBİTAK 1001 Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı 124E024 numaralı proje ile desteklenmiştir ve bu projenin önemli bir bölümünü oluşturmaktadır. Bu bağlamda öncelikle tezde beraber çalıştığımız proje yürütücüsü ve danışman hocam Prof.Dr. Mustafa Servet KIRAN'a çalışmasıyla biz örnek olduğu ve tezdeki rehberliği için teşekkür ederim. Ayrıca proje ekibi Dr. Öğr. Üyesi Engin EŞME ve Arş. Gör. Merve YILMAZ'ın katkıları yadsınamaz. Bu katkıları nedeniyle proje ekibine ayrıca teşekkür ederim.

Tezin çalışmalarının sürdürülmesi sırasındaki yapıcı eleştirisiyle katkı sunan tez komitesi üyesi Prof. Dr. Erkan ÜLKER'e ve açık fikirliliği ve yol göstericiliği ile katkı sunan Doç.Dr. Ali YAŞAR hocalarıma teşekkür ederim.

Araştırma görevlisi olarak çalıştığım süre boyunca doktora çalışmalarına destek olan mesai arkadaşım Arş. Gör. Emir Ali DİNSEL'e ayrıca teşekkür ederim. Bu bağlamda huzurlu bir çalışma ortamı bulunan Konya Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'ne ve değerli öğretim elemanlarına teşekkür etmek isterim.

Hayatımın her döneminde bana destek olan annem Elmas SEYFİ ile babam Nusrat SEYFİ'ye ve her zaman yanımda olan kardeşlerime teşekkür ediyorum.

Tez çalışmasında veri seti oluşturma sürecine destekte bulunan Konya Havalimanı Mülki İdari Amirliği ve çalışanlarına; tez çalışmasına kaynak sağlayan Türkiye Bilimsel ve Teknolojik Araştırma Kurumu Araştırma Destek Programları Başkanlığı'na; projenin yürütülmesi sırasında mevzuat ve malî prosedürler hakkındaki sorularımıza hızlı, kesin ve doğru cevaplar veren Grup Uzmanı Sayın Şevval Seray MACAKOĞLU Hanımefendi'ye ve Konya Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'ne teşekkür ederim.

Gökhan SEYFİ
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.2. Tezin Amacı ve Literatüre Katkıları	3
2. KAYNAK ARAŞTIRMASI	5
2.1. El ile Yapılan Önceki Çalışmalar	5
2.2. Derin Öğrenme Yöntemleri ile Yapılan Çalışmalar	8
2.2.1. Nesne sınıflandırma	8
2.2.2. Nesne tespit ve konumlandırma.....	11
2.2.2.1. Bölge tabanlı yöntemler	12
2.2.2.2. Tek atışlık yöntemler	16
2.2.3. Anomali tespiti.....	22
2.2.3.1. GAN tabanlı yöntemler.....	23
2.2.4. Kümeleme	24
3. MATERYAL VE YÖNTEM.....	28
3.1. X-ray Güvenlik Teknolojileri	28
3.2. X-ray Güvenlik Görüntülemesi	31
3.3. Makine Öğrenmesi ve Yapay Sinir Ağları	32
3.4. Derin Öğrenme ve Diğer Kavramlar	33
3.4.1. Evrişimsel sinir ağı	33
3.4.2. Evrişim katmanı	34
3.4.3. Havuzlama katmanı	35
3.4.4. Tam bağlı ağlar	36
3.5. Sınıflandırmada Kullanılan Derin Öğrenme Modelleri	37
3.5.1. ResNet.....	37
3.5.2. DarkNet.....	40
3.5.3. InceptionV3	42
3.5.4. EfficientNet.....	45
3.5.5. ShuffleNet	47
3.5.6. MobileNet	50
3.5.7. DenseNet.....	52
3.5.8. Xception.....	54
3.6. RWN	55
3.7. Veri Seti	57
3.7.1. Veri setinin karmaşıklığının yorumlanması.....	59

3.8. Önerilen Yöntemler	61
3.8.1. Derin öğrenme ile özellik çıkarımı	61
3.8.2. Sonradan özellik füzyonu	63
3.9. Performans Değerlendirme Ölçütleri	64
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	67
4.1. Derin Öğrenme Yöntemleri ile Özellik Haritalarının Elde Edilmesi	67
4.1.1. Derin öğrenme algoritmalarının eğitilmesi ve test edilmesi	68
4.2.1 Sınıflandırma sonuçların değerlendirilmesi	74
4.3. Birleştirme Deneyleri ve Performans Analizi.....	75
5. SONUÇLAR VE ÖNERİLER	89
5.1 Sonuçlar	89
5.2 Öneriler	90
KAYNAKLAR	93

SİMGELER VE KISALTMALAR

Simgeler

Simgeleri yazmaya buradan başlayınız ve yazım kılavuzunda belirtildiği şekilde düzenleyiniz. Simgelerin bitiminden sonra, kısaltmalar başlığından önce bir satır boşluk bırakınız.

Kısaltmalar

BT	:	Bilgisayarlı Tomografi (<i>Computed Tomography</i>)
SURF	:	Hızlandırılmış Sağlam Özellikler (<i>Speeded-Up Robust Features</i>)
HOG	:	Yönlendirilmiş Eğim Histogramları (<i>Histograms of Oriented Gradients</i>)
OTT	:	Otomatik Tehdit Tespiti (<i>Automatic Threat Detection</i>)
Roi	:	İlgilenilen Bölge (<i>Region of Interest</i>)
ELU	:	Üssel Doğrusal Birim (<i>Exponential Linear Unit</i>)
ReLU	:	Doğrultulmuş Doğrusal Birim (<i>Rectified Linear Unit</i>)
GAN	:	Karşıt Üretici Ağlar (<i>Generative Adversarial Network</i>)
CNN	:	Evrişimli Sinir Ağı (<i>Convolutional Neural Network</i>)
R-CNN	:	Bölge Tabanlı Evrişimsel Sinir Ağı (<i>Region-based Convolutional Neural Network</i>)
R-FCNN	:	Bölge Tabanlı Tam Evrişimsel Sinir Ağları (<i>Region-based Fully Convolutional Neural Network</i>)
Fast R-CNN	:	Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (<i>Fast Region-based Convolutional Neural Network</i>)
Mask R-CNN	:	Maske Bölge Tabanlı Evrişimsel Sinir Ağı (<i>Mask Region-based Convolutional Neural Network</i>)
Faster R-CNN	:	Daha Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (<i>Faster Region-based Convolutional Neural Network</i>)
TIP	:	Tehdit Görüntü Projeksiyonu (<i>Threat Image Projection</i>)
YOLO	:	Sadece Bir Kez Bak (<i>You Only Look Once</i>)
RetinaNet	:	Retina Ağı (<i>Retina Network</i>)
FPN	:	Özellik Piramit Ağı (<i>Feature Pyramid Networks</i>)
ResNeXt	:	Yeni Nesil Kalıntı Ağı (<i>Residual Next</i>)
ImageNet	:	Görüntü Ağları (<i>Image Networks</i>)

SSD	:	Tek Atışta Tespit (<i>Single Shot Detection</i> ,)
ResNet	:	Kalıntı Ağı (<i>Residual Network</i>)
ATSS	:	Uyarlamalı Eğitim Örnek Seçimi (<i>Adaptive Training Sample Selection</i>)
DWC	:	Derinlemesine Evrişim (<i>Depthwise Convolution</i>)
PWC	:	Noktasal Evrişim (<i>Pointwise Convolution</i>)
IIRS	:	İyileştirilmiş Ters Kalıntı Blok (<i>Improved Inverted Residual Block</i>)
WGAN-GP	:	Gradyan Cezalı Wasserstein Üretici Karşıt Ağ (<i>Wasserstein Generative Adversarial Network with Gradient Penalty</i>)
CSPDarknet53	:	Çapraz Aşama Kısmi Darknet53 Ağı (<i>Cross Stage Partial Dark Network</i>)
FCN	:	Tam Bağlı Evrişimsel Ağlar (<i>Fully Convolutional Networks</i>)
U-Net	:	U Ağı (<i>U Network</i>)
DeconvNet	:	Geri Konvolüsyon Ağı (<i>Deconvolutional Network</i>)
RedNet	:	Yoğun Bağlantılı Kalıntı Ağı (<i>Residual Network with Dense Connections</i>)
DDoM	:	Sık Yeniden Bindirme Modülü (<i>Dense De-overlap Module</i>)
ADM	:	Dikkat Deforme Edici Modül (<i>Attention Deforming Module</i>)
O2OFM	:	Birebir Füzyon Modülü (<i>One-to-One Fusion Module</i>)
PAN	:	Yol Birleştirme Ağı (<i>Path Aggregation Network</i>)
MA-Net	:	Karşılıklı Dikkat Ağı (<i>Mutual Attention Network</i>)
PSPNet	:	Piramit Sahne Ayrıştırma Ağı (<i>Pyramid Scene Parsing Network</i>)
BoW	:	Kelime Çantası (<i>Bag of Words</i>)
SVM	:	Destek Vektör Makinesi (<i>Support Vector Machine</i>)
SR	:	Seyrek Temsiller (<i>Sparse representations</i>)
DCGAN	:	Derin Evrişimsel GAN (<i>Deep Convolutional Generative Adversarial Network</i>)
VGGNet	:	Görsel Geometri Grubu Ağı (<i>Visual Geometry Group Network</i>)
SIXray	:	X-ray Güvenlik Görüntüleme (<i>Security Inspection X-ray</i>)

Inception	:	Inception Ağı (<i>Inception</i>)
PGGAN	:	Aşamalı Büyüyen Karşıt Üretici Ağ (<i>Progressively Growing Generative Adversarial Network</i>)
DenseNet	:	Yoğun Bağlantılı Ağ (<i>Densely Connected Convolutional Networks</i>)
SOTA	:	En Son Başarıyı Temsil eden (<i>State-of-the-Art</i>)
SCAB	:	Uzaysal ve Kanalsal Dikkat Bloğu (<i>Spatial-and-Channel Attention Block</i>)
Bi-GAN	:	İki Yönlü Karşıt Üretici Ağlar (<i>Bidirectional Generative Adversarial Networks</i>)
RGB	:	Kırmızı Yeşil Mavi (<i>Red Green Blue</i>)
SegNet	:	Segmentasyon Ağı (<i>Segmentation Network</i>)
DDoAS	:	Yoğun Çakışma Giderici Dikkat Yılan Ağı (<i>Dense De-Overlap Attention Snake</i>)
MobileNet	:	Taşınabilir Ağ (<i>Mobile Network</i>)
RWN	:	Rastgele Ağırlıklı Ağlar (<i>Random Weight Networks</i>)
ELM	:	Aşırı Öğrenme Makinesi (<i>Extreme Learning Machine</i>)
SP	:	Uyarılmış Fosfor (<i>Stimulable Phosphor</i>)
SLF-HMAX	:	Hiyerarşik Maksimum Havuzlama için Seyrek Doğrusal Özellikler (<i>Sparse Linear Features for Hierarchical Max Pooling</i>)
AUC	:	Eğri Altındaki Alan (<i>Area Under the Curve</i>)
OPIXray	:	Üst üste Binmiş Yasaklı Maddeler (<i>Occluded Prohibited Items X-ray</i>)
EAOD-NET	:	Etkili Anomali Nesne Tespiti Ağları (<i>Effective Anomaly Object Detection Networks</i>)
Evr	:	Evrişim (<i>Convolution</i>)
Maks. Hav	:	Maksimum Havuzlama (<i>Maximum Pooling</i>)
Ort. Hav.	:	Ortalama Havuzlama (<i>Average Pooling</i>)
TB	:	Tam Bağlı (<i>Fully Connected</i>)
MBEvr	:	Taşınabilir Dönüştürülmüş Darboğaz Bloğu (<i>Mobile Inverted Bottleneck Block</i>)
A	:	Adım (<i>Step</i>)
DB	:	Derinlik Bazlı

YN : *(Depth Wise)*
Yığın Normalleştirme
(Batch Normalization)



1. GİRİŞ

X-ray görüntüleme teknolojileri X-ray ışınının Wilhelm Conrad Röntgen tarafından keşfinden itibaren günlük hayatta birçok yerde, kristalografi, astronomi, tıp vb. alanlarda ve geleneksel iletim (conventional transmission), çift enerjili (dual energy), bilgisayarlı tomografi (computed tomography, BT), dağılımsal görüntüleme (scatter X-ray) gibi çok farklı amaç ve teknolojilerle kullanılmaktadır (Wikipedia, 26.08.2022). İlgili teknolojilerde bir veya birden fazla X-ray kaynağından çıkan ışınlar kaynağın yakınına yerleştirilmiş insan, eşya vb. maddelerden yansıyarak azalmaya uğrar. Bu azalma bilgisi ilgili maddelerin yoğunluğu (d) ve etkili atom numarası (Z_{eff}) hesaplanması amacıyla kullanılır (Singh ve Singh, 2003). Yoğunluğu yüksek olan maddeler klasik X-ray görüntülerinde yansımadan ötürü daha açık renklerde, düşük olanları ise yansıma olmadığı veya daha az olduğu için koyu renklerde görünmektedirler. X-ray cihazlarının sunduğu bu bilgiler doğrultusunda X-ray teknolojileri çok farklı amaçlarda yaygın bir şekilde kullanılmaktadır. Sanayi vb. kuruluşlarda yapılan kaynakların (welds) kontrol edilmesi (Liu ve diğ., 2022c), insan vücudu içerisindeki kemiklerin kırık olup olmadığının belirlenmesi (Hardalaç ve diğ., 2022) gibi birçok kullanım şekli örnek olarak verilebilir. Aynı şekilde, X-ray cihazları güvenlik amacıyla kullanıldığında, silahlar, bıçaklar gibi metalik eşyalar kolaylıkla tespit edilebilir. Bu cihazlar, havalimanları, adliyeler, alışveriş merkezleri ve metrolar gibi X-ray görüntüleme cihazına sahip olan birçok mekânda, yasaklı maddelerin tespiti için yaygın olarak kullanılmaktadır (Miao ve diğ., 2019).

X-ray görüntüleri üzerinde yasaklı madde tespiti, havalimanlarında güvenlik riskinin en aza indirgenmesi maksadıyla yolcuların yanında veya bagajlarında taşımaları yasaklı olan maddelerin 3-b veya 2-b X-ray görüntüleri vasıtasıyla otomatik tespiti olarak tanımlanabilir (Mery ve diğ., 2013). Bu uygulamalar genellikle bagaj kontrolünü gerçekleştiren görevliye yardım amacıyla veya süreci otomatikleştirme maksadıyla kullanılmaktadır.

Literatürde farklı uygulamalar geliştirilerek çeşitli yönlerden araştırılmasına rağmen X-ray üzerinde nesne tanıma aşağıdaki sebeplerden dolayı ucu açık bir soru olarak kalmaya devam etmektedir.

- i) Test nesnelerinin görünüş ve şekillerinin çok çeşitli olması,
- ii) Bakış noktasına bağlı (üst görünüm, önden görünüm vs.) olarak nesne örneklerinin çok çeşitli olması,

- iii) Üst üste gelme, gürültü ve elde edilme yöntemlerinin farklılığı gibi durumlardan ötürü test nesnesinin görüntüsünün çok çeşitli olması (Mery ve diğ., 2013).

X-ray teknolojileri havalimanı güvenliğinde uzun zamandan beri kullanılmaktadır. Ancak bu alanda bilgisayarlı görme yöntemlerinin kullanımı önceleri yalnızca bagaj görevlisine yardımcı sınırlıydı (Flitton ve diğ., 2013). Günümüzde ise özellikle derin öğrenme yöntemlerinin başarısı ile diğer alanlarda olduğu gibi bu alanda da kullanımı hızla artmaktadır.

Türkiye’de ve dünyada son yıllarda terör saldırılarının artışı ile birlikte havaalanı, alışveriş merkezleri, bakanlıklar gibi özel ve devlet kurumlarının güvenlik ihtiyacı vazgeçilmez hale gelmiştir. Bu kuruluşlarda güvenlik X-ray cihazları vasıtasıyla çanta, bagaj vs. içerisindeki eşyaların iki boyutlu veya üç boyutlu görüntüleri elde edilerek bir ekrana yansıtılması ve bu ekrana bakan bir insan uzman tarafından tehlikeli maddelerin tespit edilmesi şeklinde sağlanmaktadır. Ancak yapılan bu işlem zaman darlığı, iş yoğunluğu, uzman personel eksikliği gibi nedenlerden dolayı verimli ve/veya güvenilir olmamaktadır. Kontrolleri gerçekleştiren görevlilerin dikkatlerini sürekli bu ekranda tutmaları ve dağıtmamaları gerekmektedir. Ayrıca patlayıcı maddeler ve ilgili devre elemanlarının bu görüntü üzerinden tespiti de oldukça zordur. Özellikle çanta ve bagajlarda eşyalar üst üste ve yan yana gelerek görüntüde tespit zorluğuna sebep olmaktadır. X-ray cihazlarından elektronik cihazlar (özellikle dizüstü bilgisayarlar) ayrı kutularda geçirilmesine rağmen görüntüyü takip eden uzman personelin elektronik cihazın içerisinde gizlenmiş bir bomba düzeneğini varsa belirlemesi beklenmektedir. Bu görev ise elektronik mühendisliği veya bilgisayar mühendisliği gibi dizüstü bilgisayarın içerisinde olması muhtemel kartları bilen biri tarafından dahi zorlukla gerçekleştirilebilecek bir işlemdir. Bu tez çalışmasında ilgili sürecin görüntü işleme ve derin öğrenme vasıtasıyla otomatikleştirilip hata oranının en aza indirilmesi hedeflenmektedir. İlgili devrelerin metal aksamını X-ray görüntüsünde tespit edip işleyerek dizüstü bilgisayar vb. diğer elektronik eşyalar içerisinde gizlenen bu maddelerin tespiti amaçlanmıştır. Bu amacı yerine getirebilmek maksadıyla öncelikle belirli sayıda eski/yeni dizüstü bilgisayar kasası içerisine olmaması gereken bazı devreler yerleştirilmiş, daha sonra farklı açılarda ve yerleşimlerde X-ray cihazından görüntüleri elde edilmiştir. Sonraki aşamada bu görüntüler derin öğrenme yöntemlerinin eğitimi için kullanılmıştır.

Oluşturulan bu yeni veri seti ile başlı başına bir derin öğrenme tabanlı uygulama ile dizüstü bilgisayar içerisinde olmaması gereken devrenin tespiti yapılmıştır.

Önerilen yöntem iki aşamadan oluşturulmuştur. İlk olarak tamamen özgün yeni bir veri seti oluşturulmuştur. Daha sonra bu veri üzerinde ön işleme yapılmıştır. Sonraki aşamada bu yeni veri seti ile literatürde bulunan derin öğrenme mimarileri kullanılarak modeller eğitilmiş ve test ve doğruluk performansları incelenmiştir. Özellikle veri setinin boyutunun ve maliyetin getirdiği sorunlar incelenerek başarı artırımı için sonradan özellik birleştirme kullanılmıştır. Bu yöntemde iki farklı derin öğrenme yönteminden elde edilen özellik haritaları birleştirilerek sınıflandırma performansını iyileştirmek için Rastgele Ağırlıklı Ağlar (Random Weight Networks, RWN) kullanılmıştır ve sonuçları değerlendirilmiştir.

1.2. Tezin Amacı ve Literatüre Katkıları

Derin öğrenme birçok alanda başarıyla kullanılmaktadır. Bunlardan birisi olan X-ray güvenlik görüntüleme mevcut veri setleri ve uygulamalar çanta ve içerisindeki nesnelerin tespitine yoğunlaşmıştır. Ancak incelenen literatürde dizüstü gibi elektronik eşyalar içerisinde gizli patlayıcı vb. devrelerinin incelenmediği görülmüştür. Bu sistemlerin amacı güvenliği en yüksek seviyeye getirmek olduğu için problemin bu önerdiğimiz yeni yaklaşımla çözümü sürecin güvenilirliğini artıracaktır. Bu süreç ile alakalı literatürde birebir aynı çalışma ve veri seti bulunmamaktadır. Yapılan bu çalışma ile ilgili sürecin ve veri setinin literatüre tanıtılması amaçlanmıştır. Bu sayede konu ile ilgili yapılabilecek çalışmalara referans olunacaktır. Bu tez çalışmasında, X-ray görüntüleme sistemlerinde daha başarılı sonuçlar elde edebilmek amacıyla derin öğrenme modelleri geliştirilmiş ve bu modellerin gerçek hayatta uygulanabileceği senaryolar oluşturulmuştur. Bu sayede, daha verimli ve güvenilir X-ray görüntüleme sistemleriyle ilgili dikkatler bu alana çekilmeye çalışılacaktır. Gerçekleştirilen bu sürecin otomatikleştirmesi sağlanmış ve bu sayede hata oranlarının en aza düşürülmesi amaçlanmıştır. Oluşturulan veri seti ile literatüre katkı sağlanması hedeflenmiştir.

Gerçekleştirilen tez çalışması toplamda beş bölümden oluşmaktadır. Tezin birinci bölümü giriş kısmı olup ikinci bölümde kaynak araştırması adı altında X-ray güvenlik görüntüleme üzerine yapılan çalışmalar sunulmuştur. Üçüncü bölümde tez kapsamında kullanılan materyal ve yöntemden bahsedilmiştir. Dördüncü bölümde ise gerçekleştirilen

alışmalar ve elde edilen bulgular anlatılmıştır. Beşinci bölüm, son bölüm olup sonuçlar ve öneriler kısmından oluşmaktadır.



2. KAYNAK ARAŞTIRMASI

Bu bölümde yapılan kaynak araştırması mevcut çalışmaların içerikleri göz önünde bulundurularak derin öğrenme yöntemleri ve el ile yapılan önceki çalışmalar olarak iki ana başlığa ayrılmıştır. Derin öğrenme yöntemleri ise yapılan etüt çalışması ve literatür göz önünde bulundurularak X-ray görüntülemenin kullanım amacına göre dört alt başlığa ayrılmıştır. Kaynak araştırması bölümünde kısaca güvenlik görüntüleme konusuna getirilen yaklaşımların tanımları, kapsamaları ve yıllar içerisinde gelişimleri sırasıyla verilmiştir. Bölüm sırasıyla 1) El ile yapılan çalışmalar 2) Derin Öğrenme ile yapılan çalışmalar halinde iki ana başlık olarak incelenmiştir. Derin öğrenme çalışmaları ise kendi içerisinde dört alt başlık sırasıyla 1) Sınıflandırma 2) Nesne tespiti 3) Anomali tespiti 4) Kümeleme olarak bölümlenmiştir.

Bu çalışma kapsamında yapılmış olan literatür taramasında görülen eksiklikler ise; X-ray güvenlik görüntüleme probleminin, daha önce patlayıcı devresi tespiti için kullanılmadığı görülmüştür.

2.1. El ile Yapılan Önceki Çalışmalar

Önceki yıllarda el ile işlenen Haar benzeri (Haar-like) özellikler, Yönlendirilmiş Eğim Histogramları (Histograms of Oriented Gradients, HOG), Yerel İkili Şablon (Local Binary Pattern, LBP) ve Ölçek Sabit Özellik Dönüşümü (Scale Invariant Feature Transform, SIFT) gibi görüntü özellikleri çoğu görüntü tespit görevinde yaygın olarak kullanılıyordu. Bu özellikler görüntüyü farklı yönlerden tanımlarlar ancak kısıtlı açıklama yeteneklerine sahiptirler. Örneğin Renk histogramı görüntüdeki renk dağılımını gösterir. Canny kenar (edge), Gabor tepkisi (response) ve LBP tanımlayıcısı ise görüntünün kenar ve doku bilgisini gösterir. HOG, insan algılamasına çok yararı olan nesnelerin şekillerini tanımlayabilir. SIFT ve Hızlandırılmış Sağlam Özellikler (Speeded-Up Robust Features, SURF) tanımlayıcıları, hedefin ayrıntılarını yansıtan görüntünün yerel özelliklerini sağlar. Kelime Çantası (Bag of Words, BoW) ise bu tanımlayıcıları nesne tanıma görevi için yerel özellik sözlüğü olarak bir araya getirir. Ancak el ile çıkarılan özellikler görüntü içeriğini her yönüyle tanımlayamaz, dolayısıyla karmaşık görevlerde tespit doğruluğu sınırlıdır (Tianyu ve diğ., 2018). Bundan sonraki kısımda bu başlık altında yer alan çalışmalar sırasıyla verilmiştir.

Ioannou (2008) aldığı patentte bir veya daha fazla özel yazılım tabanlı görüntü işleme ve tespit yöntemlerini çalıştıran atanmış bir bilgisayar işlemcisi içeren X-ray tabanlı BT denetleme sistemi oluşturmuştur. Diğer özellikleri ve avantajların yanı sıra, yeni yöntemlerinde düşük çözünürlüklü BT hacimsel verilerinden düşük çözünürlüklü Uyarılmış Fosfor (Stimulable Phosphor, SP) görüntüleri oluşturarak, verimi önemli ölçüde artırmıştır. Oluşturulan sistemde bir görüntü işleme ve tespit yöntemi, oluşturulan SP görüntülerini kümelere ayırıp analiz etmektedir ve önceden talep edilen düşük çözünürlüklü yeniden yapılandırılmış BT görüntülerinin yeterli olup olmadığına veya ek yüksek çözünürlüklü yeniden yapılandırılmış BT görüntülerine gerek olup olmadığına karar vermektedir.

Mahdavi (2009) aldığı patentte pafta (sheet) patlayıcılar vb. gibi farklı potansiyel tehditlerin varlığını veya yokluğunun tespit edildiği bir yöntem geliştirmiştir. Bu ise X-ray resmindeki bölgelerin saptanması istenen ilgili madde ile ilişkili olup olmadığını belirlemek için, bir X-ray resmindeki bölgelerin gradyan bilgilerinin belirlenmesini içeren çeşitli yerel ve/veya global gradyan analizi yöntemleri ile sağlanır. Bu bilgiler kaçak mal, patlayıcılar veya yasaklanmış diğer materyallerin belirlenmesi için kullanılabilir.

Schmidt-Hackenberg ve diğ. (2012) , hazırladıkları konferans makalesinde SIFT ve PHOW gibi popüler BoW yöntemlerini, Hiyerarşik Maksimum Havuzlama için Seyrek Doğrusal Özellikler (Sparse Linear Features for Hierarchical Max Pooling, SLF-HMAX) ve V1-like (benzeri) beynin görsel korteksinde esinlenmiş özelliklerle kıyaslamışlardır. Bunun için, oluşturdukları veri集中的 resimlerin özelliklerini bu yöntemlerle çıkararak, SIFT ve Piramit Yönlendirilmiş Eğim Histogramları (Pyramid Histogram of Oriented Gradients, PHOW) ile BoW oluşturmuşlardır. Sonraki aşamada, bu dört özellik kümesi için doğrusal ikili Destek Vektör Makinesi (Support Vector Machine, SVM) sınıflandırıcılar kullanmışlardır. Son olarak, maksimum olmayanların bastırılması (non-maximum suppression) yöntemini uygulayarak yaptıkları tahminlerin başarılarını diğer iki yöntemle kıyaslamışlardır.

Franzel ve diğ. (2012) hazırladıkları konferans makalesinde çok görünüm (multi-view) X-ray görüntüleri üzerinde nesne tespiti yapan otomatik bir yöntem geliştirmişlerdir. Kullanılan üç boyutlu yöntemde, üç boyutlu görüntüyü çok sayıda görüş açısından alınan tek bir girdi görüntü gibi algılayan önceki çalışmaların aksine, üç boyutlu görünümü çok sayıda girdi görüntüsü ile oylama tabanlı bir yaklaşımla birleştiren bir yöntem kullanmışlardır. Bunun için X-ray görüntülerinde bulunan görünümdeki

çeşitlilikleri ve bozulmaları analiz etmişlerdir. Bunun sonucunda ilgili bozulmayı en aza indirmek maksadıyla ortografik yansıtma (orthographic projection) yöntemiyle her bir görüntü satırını 3 boyutlu uzaya yeniden yansıtılmışlardır. Bu yöntemin başarısını, oluşturdukları veri seti ile yapılan deneylerde, tabanca tespiti için tek görünümlü ve çok görünümlü HOG özellikleri ve SVM sınıflandırıcı kayan pencereler yöntemlerinin kullanılmasıyla göstermişlerdir.

Hazırladıkları konferans makalesinde Mery ve diğ. (2013) iyice belirlenmiş şekil ve boyutlara sahip belirli sıradan nesneleri tanımak için çok görünümlü X-ray görüntüsüne dayanan otomatik bir yöntem önermişlerdir. Yöntem iki adımdan oluşmaktadır: "monoküler analiz" ve "çoklu görüş analizi". Monoküler Analiz adımı, sistemin her bir görünümü tek tek analiz ettiği ve bu görünümün her birinde potansiyel tespitler veya ilgili nesneleri belirlenmeye çalışıldığı bir süreç gerçekleşmektedir. Çoklu Görünüm Analizi: Monoküler analiz ile her bir görünümünden potansiyel tespitler elde edildikten sonra, birden fazla görünümünden gelen bilgiler birleştirilerek ilgili nesnelerin tanınması ve belirlenmesi sağlanmaktadır. Genellikle, farklı görünümünler arasında tespitleri eşleştirerek sahne veya gözlemlenen nesnelerin daha kapsamlı bir anlayışını oluşturmaya çalışmışlardır. Bunun dışında eşleşen adayların aranmasını çevrimdışı hesaplanan bir arama tablosu kullanarak verimli bir şekilde gerçekleştirmişlerdir.

Hassanpour (2016) hazırladığı makalede güvenlik ve kontrol sistemlerinde yaygın olarak kullanılan çift enerjili X-ray sistemleri üzerinde bir çalışma yapmıştır. Çalışmada insan operatörlere yardımcı olmak maksadıyla üst üste binen maddeleri tespit etmek ve birden fazla görüntüyü yeniden yapılandırarak bu üst üste binmeleri azaltmayı hedefleyen yeni bir yöntem önermiştir. Deneyisel sonuçlar, yeniden yapılandırılan görüntülerin, insan operatörler tarafından incelenmesinin işlenmemiş orijinal görüntülerden çok daha kolay olduğunu göstermiştir.

Yukarıdaki yasaklı madde tespiti çalışmalarının dışında X-ray görüntüleme farklı alanlarda el ile yapılan çalışmalar sırasıyla verilmiştir. Kristal tespiti (Liu ve diğ., 2008), yiyecek sektöründe balık filetosunda kemik (Mery ve diğ., 2011) veya tahıllarda böceklenme (Karunakaran ve diğ., 2004) tespiti, sağlık sektöründe organların (Mueen ve diğ., 2007; Avni ve diğ., 2010b; Kim ve diğ., 2010) veya hastalıkların (Avni ve diğ., 2010a; Wu ve diğ., 2012) tespiti , kemik yaşının (Seok ve diğ., 2012) veya kırıklarının (Lim ve diğ., 2004) tespiti, dökümlerdeki hata tespiti (Pieringer ve Mery, 2010; Mery, 2011) gibi konularda basit özellik çıkarım teknikleri kullanılarak sınıflandırma vb. görevler gerçekleştirilmiştir.

2.2. Derin Öğrenme Yöntemleri ile Yapılan Çalışmalar

Bu kısımda özellikle AlexNet'in başarısıyla kullanımı artan ve oldukça başarı gösteren derin öğrenme yöntemleri ayrı birer başlık altında kullanım alanlarına göre gruplanmıştır. Sırasıyla verilen dört alt başlık altında her birinin kapsamı ve tanımı belirtilerek o kısımda yapılmış çalışmalar sıralanmıştır.

2.2.1. Nesne sınıflandırma

Sınıflandırma teknikleri denetimli öğrenme kategorisine giren yöntemlerden birisidir. Bu yöntemde yeni bir örneğin sınıfı, cinsi vb. önceden var olan bir veri seti üzerindeki örneklerden öğrenilerek mevcut sınıflardan biri olarak belirlenir. X-ray güvenlik görüntülemesi alanında sınıflandırma ise ilgili görüntüler arasından tehlikeli veya yasak maddeler içeren örneklerin belirlenmesidir. Bu alanda yapılan ilk çalışmalarda genellikle basit Evrişimli Sinir Ağları (Convolutional Neural Network, CNN) kullanılmıştır. Araştırmamızda derin öğrenme üzerinde yapılan ilk çalışmanın Akçay ve diğ. (2016) tarafından yapılan çalışma olduğunu tespit etmiş bulunmaktayız.

Akçay ve diğ. (2016) hazırladıkları konferans makalesinde X-ray bagaj görüntüsü tarama bağlamında ortaya çıkan görüntü sınıflandırma probleminde CNN kullanımını transfer öğrenimini ile incelemişlerdir. CNN'lerin eğitimi çok fazla veri gerektirdiği ve çok fazla eğitim verisi bulunamadığından yeterince eğitim verisinin var olduğu genel görüntü sınıflandırma görevlerinden önceden eğitilmiş bir CNN'nin öğrenme paradigmasını transfer etmişlerdir. İlgili paradigmada ağın son katmanlarını dondurup ilk katmanlarını ince ayarlama işlemine tabi tutarak optimize etmişlerdir. Geliştirdikleri yöntemi literatürde daha önce bulunan SVM tabanlı BoW gibi çalışmalar ile kıyaslamışlardır. Silah tespiti konusunda oldukça başarılı sonuçlar elde etmişlerdir. Daha sonra değerlendirmelerini çoklu nesne sınıflandırma üzerine de genişletmişlerdir.

Mery ve diğ. (2016) hazırladıkları makalede X-ray bagaj kontrolündeki nesne tespiti alanında son yıllarda önerilen 10 farklı bilgisayarla görme stratejisini kıyaslamışlar ve test etmişlerdir. Bu yaklaşımlardan bazıları BoW, Seyrek Temsiller (Sparse representations, SR), derin öğrenme ve klasik örüntü tanıma şemaları vb. olarak sıralanabilir. Çalışmalarında GDXray (GRIMA X-ray veri seti) veri setini kullanmışlardır. Ayrıca bilinen bilgisayarla görme algoritmalarını birleştiren yeni iki

algoritma da sunmuşlardır (Seyrek KNN). Yöntemlerin performansını tespit için 3 farklı tehdit nesnesinin tespitini yapmaya çalışmışlardır.

Caldwell ve diğ. (2017) hazırlamış oldukları konferans makalesinde X-ray güvenlik görüntüleri kullanarak Otomatik Tehdit Tespiti (Automatic Threat Detection, OTT) problemini Görsel Geometri Grubu Ağı (Visual Geometry Group Network, VGGNet) gibi bir derin öğrenme modelini farklı transfer öğrenme stratejileri ile kullanarak araştırmışlardır. Yapılan çalışmada insanlardaki görme yeteneğinin genelleme kabiliyetinden esinlenerek ilgili yeteneğin farklı X-ray güvenlik görüntüleri arasında da sağlanabilirliğini incelemişlerdir. Transfer öğrenmede test transferi ve eğitim transferi olmak üzere iki farklı senaryo kullanmışlardır. Her iki senaryoda da ilgili görüntülere çeşitli işlemler, dönüşümler uygulamışlardır.

Morris ve diğ. (2018) hazırladıkları konferans makalesinde yolcu çantalarının güvenlik X-ray taramalarında OTT görevini özellikle geleneksel patlayıcılara CNN kullanarak uygulamışlardır. Yaptıkları çalışmanın CNN'nin X-ray görüntülerine ilk uygulanması olduğunu iddia etmişlerdir. Makalede patlayıcı tespiti için CNN'leri kullanmanın ilk sonuçlarını oluşturdukları tescilsiz yeni bir veri seti olan Yolcu Bagaj Nesne Veri tabanını (Passenger Baggage Open Database) (PBOD) kullanarak sunmuşlardır. En yeni teknolojiye sahip VGG, Inception Ağı (Inception Network, Inception) vs. gibi CNN yöntemlerini kullanarak ve X-ray tarayıcılarının özelliklerinden yararlanarak, 0,95'lik bir Eğri Altındaki Alan (Area Under the Curve, AUC)'a ulaşan bir başarıyla tehditlerin güvenilir bir şekilde tespit edilmesini sağlamışlardır. Ayrıca, tehdit konumunun görselleştirmesi için ısı haritalarını da incelemişlerdir.

Yang ve diğ. (2019) çalışmalarında X-ray görüntüsü ile güvenlik uygulamalarındaki CNN'lerin kullanımında başarının veri setinin büyüklüğüne olan bağlılığından ötürü ilgili modellerin güvenilir bir biçimde çalışmasını sağlamak için çekişmeli üretici ağlar kullanan X-ray yasaklı eşya verisi artırıcı yeni bir yöntem oluşturmuşlardır. İlk olarak yasaklı maddeleri k en yakın komşu dokuma (matting) şeması ile X-ray bagaj görüntülerinden çıkartmışlardır. Daha sonra elde edilen eşya görüntülerinin pozlarının çok çeşitli olmasından ötürü uzaysal bir dikdörtgen koordinat sistemi kullanarak dört veya sekiz sınıftan birine kategorize etmişlerdir. Derin Evrimsel GAN (Deep Convolutional Generative Adversarial Network, DCGAN) Gradyan Cezalı Wasserstein Üretici Karşıt Ağ (Wasserstein Generative Adversarial Network with Gradient Penalty, WGAN-GP) ve kendi oluşturdukları Karşıt Üretici Ağlar (Generative Adversarial Network, GAN) modellerini Frechet Başlangıç Mesafesi skorları kullanarak

değerlendirmişlerdir. Son olarak üretilen resimler ile eğitilen CNN modelinin başarısını normal bir model ile kıyaslamışlardır.

Caldwell ve Griffin (2019) hazırladıkları makalede X-ray görüntülerinin fotoğraf verilerinden daha az bulunmasından, ayrıca üretiminin zor ve pahalı olmasından ötürü halihazırda çok sayıda bulunan fotoğraf verilerinden faydalanmaya çalışmışlardır. Bunun için COMPASS-XP adını verdikleri yeni bir veri seti üzerinde deneyler yapmışlardır. Bu veri setinde resim veri setinin iki yöntem arasında transfer edilebilmesi yeteneğinin araştırılması amacıyla aynı nesnenin aynı pozuna ait X-ray ve fotoğraf görüntüsü çiftleri bulunmaktadır. Deneyleri iki farklı şekilde yapmışlardır. Bunlardan birincisi temsili transfer yaklaşımı olan önceden eğitilmiş bir evrimsel ağı (ImageNet üzerinde) özellik çıkarımı için kullanılması şeklindedir. İkincisi ise ilkinin üzerine inşa edilen işlevsel transferdir. Bu yöntemi aynı eşyaya ait X-ray ve fotoğraf görüntü çiftleri kullanarak geliştirmişlerdir. Yaptıkları deneylerde oluşturulan bu veri setleri ile Yoğun Bağlantılı Ağ (Densely Connected Convolutional Networks, DenseNet), InceptionNet, Taşınabilir Ağ (Mobile Network, MobileNet) gibi yöntemleri eğiterek bazı kazanımlar elde etseler de bu kazanımlar oldukça kısıtlı bir şekilde olmuştur. Yine de yeni X-ray eğitim verisi eklemekten daha faydalı olduğunu söylemişlerdir.

Petrozziello ve Jordanov (2019) hazırlamış oldukları konferans makalesinde yolcuların çantalarının X-ray görüntülerinde ateşli silah parçalarının tespitine yönelik çeşitli algoritmaları araştırmış ve karşılaştırmışlardır. Sınıflandırma görevi için ateşlemede gerekli silahın ana parçası olan çelik namlu deliklerinin tespitine farklı sınıflandırma tekniklerini kullanarak odaklanmışlardır. İlk veri setleri el çantalarına ait X-ray görüntülerinden oluşmaktadır. Düzlem dışı dönüş sorununun (out-of-plane rotation problem) üstesinden gelmek için veri artırımından faydalanmışlardır. Ön işleme aşamasında, gürültülü ve belirsiz görüntüleri ortadan kaldırmak için standart filtreleme (yumuşatma, siyah beyaz eşikleme, kenar tespit vb.) tekniklerini uygulamışlardır. Karşılaştırma amacıyla nesne tespiti için istiflenmiş otomatik kodlayıcı, Sığ Sinir Ağları (Shallow Neural Network) ve Rastgele Ormanlar (Random Forest) algoritmalarını incelemişler ve sonuçlarını kıyaslamışlardır. Ayrıca, kargo kolilerinin çift yönlü X-ray görüntülerinden oluşan ikinci bir veri seti üzerinde de bulgularını doğrulamışlardır.

Benedykciuk ve diğ. (2021) hazırladıkları makalede güvenlik maksadıyla kullanılan X-ray tarama cihazları ile gerçekleştirilen malzeme tanıma (material recognition) problemini ele almışlardır. Çalışmada tarayıcı görüntülerini organik veya metalik olmasına göre çeşitli altı ana türe ayırmışlardır. Tüm özellik çıkarımı, temsili ve

sınıflandırma süreci için bir derin öğrenme yöntemi kullanmışlardır. Geliştirdikleri yöntemde eğitimdeki bir resim bu altı farklı türdeki malzemelerden oluşan parçalar (yamalar) kümesidir. Bu yamaların çok farklı boyutlarda olabilmesi sorununun üstesinden gelebilecek beş alt ağdan oluşan çok ölçekli bir ağ yapısı kullanmışlardır. Bu ağ parçaların (yama) paralel olarak çalışabileceği bir şekilde tasarlanmıştır. Ayrıca çalışmalarında çeşitli düzenleme (regularization) metotlarını ve Üssel Doğrusal Birim (Exponential Linear Unit, ELU) ve Doğrultulmuş Doğrusal Birim (Rectified Linear Unit, ReLU) gibi aktivasyon metotlarının mimarileri üzerindeki etkilerini incelemişlerdir.

2.2.2. Nesne tespit ve konumlandırma

Nesne tespit problemi herhangi bir resim içerisinde yer alan nesne ve/veya nesnelerin sınıflarının konumlarıyla birlikte tespit edilmesi işlemidir. Bu konumlandırma işlemi çevreleyici bir kutunun koordinatlarının belirlenmesi şeklinde yaygınlıkla kullanılır. Bunun dışında çeşitli odaklanma mekanizmaları ile ısı haritası benzeri yapılarla da konumlandırma yapılabilmektedir. İlk geliştirilen derin öğrenme yöntemleri sadece nesneyi sınıflandırma üzerine işlem yapmaktaydı. Sonraki dönemlerde geliştirilen Bölge Tabanlı Evrişimsel Sinir Ağları (Region-based Convolutional Neural Network, R-CNN) Sadece Bir Kez Bak (You Only Look Once, YOLO) benzeri yöntemler ile ilgili görüntülerdeki nesnelerin sınıflarının yanında konum bilgileri de tahmin edilmeye çalışılmıştır. Burada bölümlenme olarak R-CNN ve Tek Atışta Tespit (Single Shot Detection, SSD) ayrı birer başlık altında çalışma prensiplerine göre ayrılmıştır. Bu iki yöntemin dışında kalan çalışmalar genel başlık altına alınmıştır.

Xu ve diğ. (2018) yaptıkları çalışmada havalimanı X-ray güvenlik görüntüleri üzerinde yasaklı maddelerin konumlarının belirlenmesi ve otomatik tespiti üzerine yoğunlaşmışlardır. Çalışmalarında daha önce Cao ve diğ. (2018) tarafından gerçekleştirilen odaklanma mekanizmasının X-ray görüntülerinde de kullanabileceğini göstermek istemişlerdir. Bu sebeple insanlarınkine benzer bir odaklanma modeli ortaya koymuşlardır. Odaklanma haritaları girdi görüntülerindeki yasaklı nesnelerin konumunu ve ana hatlarını göstermektedir. Oluşturulan yöntemde klasik bir sinir ağı ile nesnenin kategorisi belirlendikten sonra bu bilgiyi kullanarak geri besleme kısmında aktifleşen nöronları katman katman belirlemişlerdir. Belirlenen nöronlar sayesinde resimdeki ilgili odaklanma haritalarını elde etmişlerdir. Ayrıca bu görüntülerin doğasından kaynaklanan gürültülü yapısının üstesinden gelmek için yanıl kısıtlama (lateral inhibition) ve zıt

odaklanma (contrastive attention) yöntemlerini birleştirerek bir sinirsel uyarıcı engelleme (neuronal stimulus inhibition) modeli önermişlerdir. Modelin yanıl kısıtlama kısmında nöronlar arasındaki zıtlığı (contrast) artırmışlar ve gürültüyü bastırmaya çalışmışlardır. Zıt odaklanmada ise görüntüde birden fazla tehlikeli nesne bulunması durumunda odaklanma haritalarının doğruluğunu artırmayı hedeflemişlerdir. GDxray görüntü veri seti üzerinde gerçekleştirdikleri deney sonuçlarında önerilen düzeneğin hem tekli hedef tespitinde hem de çoklu hedef tespitindeki etkinlik ve istikrarını göstermişlerdir.

Miao ve diğ. (2019) hazırladıkları makalede X-ray görüntüleri üzerinde yasaklı madde tespiti üzerine araştırma yapmışlardır. Alanda araştırma miktarını artırmak maksadıyla o zamana kadar mevcut veri setlerinden 100 kat daha büyük olan X-ray Güvenlik Görüntüleme (Security Inspection X-ray, SIXray) adını verdikleri bir milyon adet gerçek dünya örneklerinden oluşan büyük bir veri seti oluşturmuşlardır. Bu veri setinde gerçek dünya problemlerinde olduğuna benzer şekilde yaklaşık 1% oranında yasaklı maddeler bulunmaktadır. X-ray resimlerinin çok fazla üst üste binen nesneler içermesinden ve bunların birçoğunun gereksiz bilgiler de içermesinden dolayı bu bilgileri bastırmak maksadıyla orta seviye özellikleri hiyerarşik ve tekrarlamalı (iterative) şekilde rafine eden bir algoritma sunmuşlardır. Bu iteratif algoritmanın yavaşlığından ötürü durdurma (switch off) mekanizması ile ileri ve geri besleme tek seferde yapılmıştır. Pozitif ve negatif sınıflar arasındaki yoğun veri dengesizliği probleminin üstesinden gelmek için ise yeni bir kayıp fonksiyonu oluşturmuşlardır. Popüler birkaç ağ iskeletleri ile denenen yöntem ile hem sınıflandırma hem konumlandırma konusunda oldukça yüksek başarılar elde etmişlerdir.

2.2.2.1. Bölge tabanlı yöntemler

İlk olarak Girshick ve diğ. (2014) tarafından R-CNN yönteminin önerilmesiyle ortaya çıkmış tekniklerin genel adı bölge tabanlı yöntemler olarak geçmektedir. Bu tekniklerde nesnelerin bulunma olasılığının yüksek olduğu yerler bölge önerim aşaması vasıtasıyla belirlenir. İlgili aşamada seçici arama (selective search) veya ayrı bir derin öğrenme ağı gibi yöntemler bölgelerin belirlenmesinde kullanılır. Daha sonra bu bölgeler farklı bir derin öğrenme ağına verilerek sınıf ve konum gibi bilgilerinin belirlenmesi sağlanır. Bu kategoride yer alan yöntemler R-CNN, Hızlı Bölge Tabanlı Evrişimli Sinir Ağı (Fast Region-based Convolutional Neural Network, Fast R-CNN), Daha Hızlı Bölge

Tabanlı Evrişimli Sinir Ağı (Faster Region-based Convolutional Neural Network, Faster R-CNN) vb. olarak sıralanabilir.

Akçay ve Breckon (2017) hazırladıkları makalede geleneksel kayan pencere tabanlı evrişimsel sinir ağları tespit hatları, R-CNN ve Bölge Tabanlı Tam Evrişimsel Sinir Ağları (Region-based Fully Convolutional Neural Network, R-FCNN) gibi yöntemleri kullanarak X-ray güvenlik görüntüleri üzerinden nesne tespiti probleminin uygulanabilirliğini araştırmışlardır. Literatürdeki veri seti yetersizliğinden ötürü farklı sayıda R-CNN/R-FCNN çeşitlerini hem tekli hem de çoklu nesne tespiti problemleri üzerinde eğitmek için transfer öğrenme paradigmasını kullanmışlardır. R-CNN ve R-FCNN’ de kullanılan ilk aşama bölge önerileri geleneksel kayan pencere tabanlı evrişimsel sinir ağlarına göre daha iyi sonuçlar üretmiştir. Yaptıkları deneyler sonucunda kapsamlı arama stratejisi benimseyen kayan pencere tabanlı yöntemler el ile hesaplanan yöntemlerden daha iyi sonuçlar üretmişler ancak Faster R-CNN ve R-FCNN gibi yöntemler tarafından gölgede bırakılmışlardır. Son olarak üst üste binmiş eşyalara ait X-ray görüntüleri içerisinde nesne konumlandırma stratejileri adı verilen stratejilerine ait deney sonuçlarının performans karşılaştırmalarını yayınlamışlardır.

Steitz ve diğ. (2018) hazırladıkları konferans makalesinde havalimanı güvenlik taramasında yasaklı maddelerin tespiti için çoklu görünüme sahip X-ray görüntüleri kullanan CNN tabanlı nesne tespiti yaklaşımı geliştirmişlerdir. Geliştirdikleri yöntemde X-ray cihazlarının sahte renk (pseudocolor) uydurmada kullandıkları farklı açılardan çekilen görüntülerin 2 boyutlu özellik çıkarıcıları vasıtasıyla işlenmesi ve daha sonra her bir görünümünden gelen bu özelliklerin çok görünümlü havuzlama katmanında birleştirilmesiyle 3 boyutlu bir özellik uzayı elde edilmesi şeklinde işleyen bir yaklaşım benimsemişlerdir. Daha sonra bu özellikler 3 boyutlu bölge öneri ağı ile ilgilenilen Bölge (Region of Interest, Roi) havuzlama işlemlerine tabi tutularak yine 3 boyutlu bir Faster R-CNN’e verilmiştir. Bu ağ vasıtasıyla ilgili nesnenin sınıfı ve 3 boyutlu olarak çevreleyici kutusunu tahmin etmişlerdir. Geliştirdikleri bu havuzlama katmanında, özellik birleşiminde geometrik tutarlılığı sağlamak için görüntüleme sisteminin bilinen geometrisinden faydalanmışlardır. Çoklu Görünümlü X-ray R-CNN (Multi-view X-ray R-CNN, MX-RCNN) adını verdikleri bu yöntemi her bir görünüme (view) birbirinden bağımsız olarak uyguladıkları bir Faster R-CNN ile kıyasladıklarında hesaplama maliyeti ve 3 boyutlu durumun bozulmaması durumunda başarı olarak da daha iyi sonuçlar verdiğini göstermişlerdir.

Bhowmik ve diğ. (2019c) yaptıkları çalışmada, büyük miktarda elle açıklanmış gerçek dünya X-ray bagaj görüntülerini toplama problemini çözmek maksadıyla CNN mimarisinin eğitimi için sentetik olarak oluşturulmuş X-ray güvenlik görüntüleri üretme olasılığını araştırmışlardır. İlgili çalışmada, Tehdit Görüntü Projeksiyonu (Threat Image Projection, TIP) adı verilen yöntemi kullanarak sentetik veri artırım yaklaşımını benimsemişlerdir. TIP yaklaşımını kullanarak yüksek kaliteli sentetik X-ray görüntülerini oluşturarak gerçek ve sentetik X-ray güvenlik görüntülerinin, karmaşık X-ray bagaj görüntüleri üzerinde yasaklı nesne tespitinde CNN mimarilerinin performansını nasıl etkilediğine dair kapsamlı bir karşılaştırma sunmuşlardır. Yaptıkları çalışmada R-CNN, Faster R-CNN, Retina Ağı (Retina Network, RetinaNet) vb. yöntemleri kullanmışlardır. En yüksek performansı 0.88 mAP (mean Average Precision) ile Faster R-CNN yöntemiyle 3 sınıflı yasaklı madde tespiti problemi üzerinde elde etmişlerdir. Bu, gerçek X-ray eğitim verilerini kullanmanın faydalarını ayrıca sentetik X-ray görüntülerini kullanmanın ise zorluğunu ve potansiyelini göstermektedir.

Gaus ve diğ. (2019a) yaptıkları çalışmada X-ray güvenlik görüntüleme problemini üç farklı derin ağ yapısı kullanarak araştırmışlardır. Faster R-CNN, Maske Bölge Tabanlı Evrişimsel Sinir Ağı (Mask Region-based Convolutional Neural Network, Mask R-CNN) ve RetinaNet mimarileri ile eğitilen bu ağların X-ray tarayıcılarının değişken özelliklere sahip olması nedeniyle genelleme kabiliyetlerinin tarayıcılar arası taşınabilirliğini değerlendirmişlerdir. X-ray yasaklı madde görüntülerinin az sayıda olmasının zorluk oluşturması sebebiyle bu tarayıcılar arası genellemenin bir nesne tespit problemi olarak varlığını transfer öğrenme yaklaşımı kullanarak değerlendirmişlerdir. Yayınladıkları sonuçlarda, genelleştirilebilirlik başarısı olumlu bir performans artışı sergilemiştir. Ayrıca yasaklı madde tespiti için eğitilmiş modellere zorluk çıkaracak (şekil olarak ateşli patlayıcılara benzeyen) özel nesnelerden oluşan bir veri seti daha kullanarak karşılaştırmalar yapmışlardır.

Sigman ve diğ. (2020) hazırladıkları konferans makalesinde, daha fazla veri toplamanın derin öğrenme performansını artırdığına dikkat çekmiş ve bu işlemin elle yapılmasıyla para ve zaman harcanması yerine, gerçek dünyadan elde edilen verilerin minimum maliyetle etiketsiz olarak kullanılmasını incelemişlerdir. Bu amaçla makalede, Arka Plan Uyarlanabilir Faster R-CNN adını verdikleri yarı denetimli bir yaklaşım oluşturmuşlardır. Oluşturdukları yaklaşımda kullandıkları nesne tespiti eğitim yöntemi, derin öğrenme alanındaki Etki Alanı Uyarlama (Domain Adaptation) yöntemlerini kullanan iki aşamalı bir yöntemdir. Çalışmada daha önce açıklanan veri kaynaklarını iki

alan olarak kabul etmişlerdir: Bu alanlardan biri tehdit içeren görüntülerin elle toplandığı veri alanı, diğeri tehdit içermeyen varsayılan gerçek dünya görüntü alanıdır. Biri nesne önerilerini ayırt etmek ve diğeri görüntü özellikleri için olmak üzere iki etki alanı ayırıcı, etki alanına özgü bilgilerin kodlanmasını önlemek için ters yönde eğitilmişlerdir. Bu makalenin literatüre katkısı, etki alanına uyarlanabilir bir Faster R-CNN'nin gerçek dünyada kullanımını göstermesi olarak belirtmişlerdir. Buradaki uyarlanabilir yöntemde gerçek dünyadan gelen örneklerin patlayıcı içermeyişine dair güçlü bir varsayım kullanmışlardır.

Dumagpi ve Jeong (2021a) hazırladıkları makalede dengesiz bir X-ray veri kümesi üzerinde bilgisayarla görme algoritmalarının performansını iyileştirmede GAN tabanlı resim çoğaltma veya resim sentezi kullanımının etkilerini araştırmışlardır. Tehlikeli nesnelerin yeni örnek resimlerini oluşturmak için DCGAN ve tehlikeli nesnelerin kamera resimlerini X-ray resimlerine dönüştürmek için ise döngüsel-GAN (Cycle-GAN) yöntemlerini kullanmışlardır. Tehdit nesneleri ile arka plan resimlerini sentezleyerek yeni X-ray güvenlik görüntüleri oluşturmuşlardır. Üretilen bu sentetik verilerinde her bir tehdit nesnesinin iç dağılımını da hesaba katmışlardır. Ayrıca resimlerin döndürülmesi ve ölçeklendirilmesi gibi veri artırımı yöntemlerini de kullanarak ilgili artırım yöntemlerini detaylı olarak karşılaştırmışlardır. Ardından geliştirilen bu farklı veri artırımı yaklaşımlarını birlikte kullanarak çeşitli Faster R-CNN modellerini eğitmişler ve performanslarını büyük ölçekli bir uygulama X-ray görüntüsü veri kümesi üzerinde değerlendirmişlerdir.

Chang ve diğ. (2022) hazırladıkları makalede X-ray güvenlik görüntülemesinde nesne tespiti problemini iki aşamalı bir ağ ile çözmeye çalışmışlardır. Bu yöntem yasaklı maddelerin fiziksel boyutlarını da hesaba katarak yanlış uyarma durumlarını azaltmaktadır. Ayrıca pozitif ve negatif örnekler arasında bulunan dengesizlikten kaynaklanan kötü performans durumunu da azaltmak için zor-negatif-örnek seçimi adında bir yöntem uygulamışlardır. Bu yöntemde resim üzerinde segmentasyon yaparak negatif örneklerin bulunduğu kısımların nesne tespiti için kullanılmasıyla diğer kısımların etkisinin azaltılmasını hedeflemişlerdir. Geliştirdikleri çözümde Özellik Piramit Ağı (Feature Pyramid Networks, FPN) yöntemi ile Faster R-CNN yöntemini yukarıda bahsedilen fiziksel boyut ve zor negatif seçim mekanizması ile SIXray ve Üst üste Binmiş Yasaklı Maddeler (Occluded Prohibited Items X-ray, OPIXray) veri setleri üzerinde kullanarak deneyler yapmışlardır.

Ma ve diğ. (2022b) hazırladıkları makalede X-ray görüntülerinde nesne tespiti konusunu incelemişlerdir Etkili Anomali Nesne Tespiti Ağları (Effective Anomaly Object Detection Networks, EAOD-NET) adlı yöntemde X-ray resimlerinin doku (texture) içermemesi ve kenar bilgilerinin açık olmaması nedeniyle Yeni Nesil Kalıntı Ağına (Residual Next, ResNeXt) öğrenilebilir Gabor evrişim katmanı ekleyerek omurga (backbone) ağı olarak kullanmışlardır. Oluşturdıkları bu yöntem üç aşamadan oluşmaktadır. İlk aşama olan özellik çıkarımı aşamasında ResNeXt, Öğrenilebilir Gabor Filtreleri, Deforme edilebilir Evrişim ve Uzaysal Dikkat mekanizmasını birlikte kullanmışlardır. Deforme edilebilir evrişim yönteminde özellik haritasındaki her bir evrişim çekirdeğine farklı ağırlıklar verilerek yukarıda bahsedilen X-ray'in karakteristiklerinden faydalanmayı ve daha önemli özelliklerin öğrenilmesini amaçlamışlardır. Uzaysal dikkat mekanizması ile insan beyninin odaklanma karakteristiğini taklit ederek önemli kısımların daha fazla dikkate alınmasını sağlamaya çalışmışlardır. İkinci aşamada ise görüntüyü bir bölge öneri ağına vermişlerdir. Buradan çıkan özellikler daha sonra Sık Lokal Regresyon ve Daha Ayırt edici (Bigger discriminative) RoI havuzlama ağlarına vererek nesneleri sınıflandırmışlardır. Daha ayırt edici RoI havuzlamada dikkat mekanizması ile yeniden boyutlandırılmış bir özellik haritası elde etmişlerdir. Yerel Lokal Regresyonda ise her bir pikselin etkisini çevreleyici kutu belirlerken dikkate almışlardır. Hazırladıkları tüm bu yöntemleri SIXray ve OPIXray üzerinde değerlendirmişlerdir.

2.2.2.2. Tek atışlık yöntemler

Tek atışlık yöntemler olarak adlandırılan yöntemlerin arkasındaki ana fikir çok zaman alan bölge öneri sistemi yerine tek bir derin ağ kullanılarak sınıflandırma ve konumlandırma tahmininin yapılması bu sayede performans gerekliliklerinin azaltılmasıdır. En bilinen örnekleri YOLO, SSD olarak sıralanabilir. Bu yöntemlerden YOLO resmi ızgaralara (grid) ayırır ve bu ızgaralar üzerinde tahmin ve konumlandırma yapar. SSD'de ise az sayıda varsayılan çevreleyici kutular kümesi kullanılarak sınıflandırma ve konum tahmini yapılır. Kullanılan çevreleyici kutular farklı en boy oranları (aspect ratio) ve ölçeklendirmeye sahiptir.

Liu ve diğ. (2018) hazırladıkları konferans makalesinde gerçek zamanlı mühendislik hesaplamaları ihtiyacını karşılayabilen YOLO9000 temelli bir CNN modeli

kullanmışlardır. İlgili ağ modeli, makas ve aerosoller gibi nesneleri sınıflandırabilmektedir. Yaptıkları çalışmada elde ettikleri başarıyı yayınlamışlardır.

Zou ve diğ. (2018) hazırladıkları sempozyum makalesinde oldukça pahalı ve ağır olan çok görüntülü X-ray cihazlarının yerine elde taşınabilen tek görünümlü X-ray cihazları ile oluşturulan bir veri setinde CNN uygulayarak tehlikeli nesne tespiti deneyleri gerçekleştirmişlerdir. Makalede en önemli yenilik ise kullanmış oldukları veri artırım yönteminde kullanılan daha önce Jaccard vd. (2016) tarafından da önerilen sentezleme işlemidir. Çalışmada sadece 3 farklı nesnenin tespitine yönelmişlerdir. Makas, bıçak ve şişe görüntülerini ham veriden tespit performansını artırmak için sentetik üretimde kullanmışlardır. Sentezlenmiş verinin başarısını ölçmek maksadıyla t-test'i ile 5 farklı deney yaparak ham veri ve sentezlenmiş verinin arasındaki farkı araştırmışlardır.

Akcay ve diğ. (2018b) hazırladıkları makalede X-ray bagaj görüntülerinin sınıflandırma ve tespit görevlerinde CNN ile kullanımını araştırmışlardır. Veri seti oluşturmanın zorluklarından ötürü transfer öğrenmesi paradigmasını uygulamışlardır. Oluşturdıkları 11,627 adet X-ray görüntüsünü sınıflandırma ve konum tespiti yapmak adına farklı veri setleri şeklinde düzenlemişlerdir. İkili sınıflandırma problemi için benimsedikleri transfer öğrenme stratejisini Görüntü Ağları (Image Networks, ImageNet) veri tabanı üzerinde katman dondurma ve ayrıca ince ayar yapma yöntemlerinin ikisini de kullanarak gerçekleştirmişlerdir. Bu sayede her bir katmanın toplam başarıma etkisini gözlemlemeye çalışmışlardır. Bunun dışında son katmandaki tam bağlı ağ yapısının yerine bir SVM sınıflandırıcısı kullanarak elle çıkarılan özellik haritaları ile bu yöntemi kıyaslamışlardır. Konum tespiti problemi için ise Faster R-CNN, R-FCNN, YOLOv2 ve klasik pencere kaydırmalı yöntemlerini yine ImageNet veri seti üzerinde transfer öğrenimi stratejisi ile eğiterek kıyaslamışlardır. Tespit için oluşturdukları veri setini eşyaların üst üste bineceği şekilde düzenlemişlerdir. Daha sonra yöntemlerin performans kıyaslamalarını göstermişlerdir.

Liang ve diğ. (2019) hazırladıkları konferans makalesinde Ulaşım Güvenliği yönetimine yardımcı olmak maksadıyla otomatik olarak tehlikeli maddelerin tespitini ve konumlandırmasını gerçekleştirmeye çalışmışlardır. TSA (Transportation Security Administration) ile iş birliği içinde çok geniş içerik ve çeşitlilikte yasaklı maddeler içeren oldukça büyük bir veri seti oluşturarak farklı derin evrimsel nesne tespiti modellerini eğitmişler ve gerçek zamanlı olarak çalışabilen fonksiyonel bir prototipe sahip olabilecek bir tarayıcıya entegre etmişlerdir. Çalışmada özellik çıkarımı ve nesne tespiti yapmak için derin öğrenme yöntemlerinin bütünsel kullanımını incelemişlerdir. Bu amaçla SSD ve

Faster R-CNN yöntemlerini Inception, Kalıntı Ağları (Residual Network, ResNet), InceptionResNet gibi yöntemler ile birlikte kullanmışlardır. Yaptıkları çalışmalara ait sonuçları yayınlamışlardır.

Jain (2019) yapmış olduğu çalışmada havalimanı güvenliğinde hayati öneme sahip olan X-ray taraması için süreci otomatikleştirmeye çalışan bir yöntem geliştirmiştir. Bu alanda sınırlı sayıda veri seti bulunduğu için yeni X-ray fotoğraflarının mevcut resimlerdeki nesnelerin başka resimlere bindirilmesi ile gerçekleşen yeni bir sentetik resim üretme yöntemi önermiştir. Ayrıca elde ettiği veri setinin gerçek dünyayı daha iyi temsil edebilmesi için döndürme, eğme, yakınlaştırma, çarpıtma gibi teknikleri kullanarak veri artırımı yapmıştır. Elde ettiği bu veri setini kullanarak derin öğrenme tekniklerinin eğitimi gerçekleştirmiştir. İnşa ettiği yapıda nesne tespiti için kullanmış olduğu CNN modelleri YOLO ve Alan Tabanlı yöntemlerden olan Faster RCNN'dir. Ayrıca tespit başarısını artırmak için transfer öğrenme tekniği de kullanmıştır. Performansı 4 nesne sınıfı üzerinde araştırmışlardır. Bunlar: sırasıyla 1) Tabanca 2) Ninja yıldız bıçağı 3) Jilet 4) Bıçak. Yapmış oldukları deneylerde elde ettikleri sonuçları yayınlamıştır.

Saavedra ve diğ. (2020) hazırladıkları makalede X-ray ile tehlikeli nesnelerinin tespiti alanındaki araştırmaları geliştirmeyi amaçlamışlardır. İlgili derin öğrenme modellerin kullanılması için gerekli veri setleri yeterince büyük olmadığı için çözüm olarak mevcut çok sayıda tehlikeli madde içermeyen X-ray resimlerine Aşamalı Büyüyen Karşıt Üretici Ağ (Progressively Growing Generative Adversarial Network, PGGAN) stratejileriyle yapay olarak üretilen tehlikeli görüntülerin bindirilmesi (superimposition) şeklinde gerçekleşen sentetik görüntü üretim tekniğinin kullanımını araştırmışlardır. Üretilen bu taklit resimleri YOLO, SSD, RetinaNet gibi en üst seviye tespit modellerini eğitmek için kullanmışlardır. Yöntemlerini gerçek X-ray fotoğrafları üzerinde dört farklı nesnenin (silah, bıçak, jilet ve Ninja yıldız bıçağı) tespitini yaparak farklı deneylerle test etmişlerdir.

Subramani ve diğ. (2020) hazırladıkları makalede X-ray görüntüleme probleminin bir alt kümesi olan bagaj X-ray içerisindeki kesici nesneleri tespitine yönelik derin sinir ağı tabanlı bir çözüm önermişlerdir. X-ray görüntüleme sistemleri konusundaki o güne kadarki mevcut CNN tabanlı çalışmaların bölge tabanlı mimariye sahip olmasından dolayı ilgili sistemlerde SSD ve RetinaNet gibi yöntemlerin kullanımını araştırmışlardır. Deneylerini SIX-ray10 adlı veri seti üzerinde gerçekleştirmişlerdir. İlgili kesici aletlerin veri setinde oransal olarak az bulunmasından dolayı aşırı ezberlemeyi engellemek için

çeşitli denemeler yapmışlardır. InceptionV3 ve ResNet-50 yöntemlerini SSD ve RetinaNet ağları üzerinde arka uç (backend) olarak kullanarak hesaplama maliyetini azaltmak için özellik çıkarımı yapmışlardır.

Wei ve Liu (2020) yazdıkları makalede tehlikeli eşya içeren X-ray görüntüsü veri setleri oluşturmanın zor olmasından ötürü bu alanda nesne tespiti yapmak maksadıyla SSD ağları kullanarak sınıflandırma ve konumlandırma görevini çoklu görev transfer öğrenme yöntemini kullanarak gerçekleştirmişlerdir. Transfer öğrenme stratejilerinde Yoğun Bağlantılı Ağ (Densely Connected Convolutional Networks, DenseNet) yönteminden ilham almışlardır. DenseNet'tekine benzer bir yapı oluşturmak için modellerine sık blok (DenseBlock) ve geçiş (Transition) katmanı eklemişlerdir ve bunu sadece transfer katmanı adı verilen kısımda kullanmışlardır. İlgili yöntemde başka alandan alınan ağırlık bilgilerini ilk atama esnasında kullanmışlardır. Eğitim aşamasında ise bu ağın yalnızca yukarıda bahsedilen kısmı olan transfer katmanını güncellenmişlerdir. Yani çalışmadaki odak noktası SSD ağına ek evrişim katmanı ekleyerek kaynak alanından (domain) öğrenilen modelin bilgilerinin yeniden öğrenilmesidir. Deneyler de göstermiştir ki klasik ince ayar yöntemlerine göre bu yöntem SSD ağlarına daha iyi transfer öğrenme kabiliyeti kazandırmıştır.

Wu ve Liao (2022) hazırladıkları makalede çantaların güvenlik taraması işleminde bir tek atışlık derin öğrenme modeli olan YOLOv3'ü kullanmışlardır. YOLOv3'ün sahip olduğu çeşitli dezavantajların üstesinden gelmek için kademeli çaprazlama aşaması (cascaded cross-stage) isimli bir yöntemi de ekleyerek ilgili YOLO modelini iyileştirmişlerdir. Yapılan iyileştirmeler omurga YOLO'da kademeli çaprazlama aşamalı bir DarkNet ağı kullanılması ve omurga ağdan sonra bir uzaysal piramit havuzlama (spatial pyramid pooling) modülünün kullanılmasıdır. Son iyileştirme ise aşağıdan yukarıya (bottom-up) doğru piramitteki özelliklerin birleştirilmesi ile hesaplama hızı ve modelin özellik çıkarımını artıran FPN modülüdür. Modül sayesinde semantik ve konumsal bilgilerin daha iyi iletilmesi sağlanmıştır. Veri seti olarak SIXray'i mozaik veri artırımı metodu ile ön işleyerek kullanmışlardır. Son olarak geliştirilen bu yöntemi literatürdeki SSD ve Faster R-CNN gibi modellerle karşılaştırmışlardır.

Nguyen ve diğ. (2022) hazırladıkları makalede X-ray resimlerinin güvenlik için kullanımında son yıllarda yaygınlaşan derin öğrenme yöntemlerinin performanslarının artırılmasına yönelmişlerdir. Bunun için X-ray resimlerinde bulunan değişik resim boyutları, en boy oranı ve hedef nesnelerin boyutlarının küçük olması durumunda gereksiz bilgilerin fazla olması gibi problemlerin üstesinden, hedef yönelimli resim

kesme isimli yöntem vasıtasıyla gelmeye çalışmışlardır. Bu yöntemde girdi görüntüsü birkaç katmandan oluşan evrişim işlemine tabi tutularak elde edilen aktivasyon haritaları ile gereksiz kısımlar belirlenip resimden atılmaktadır. Bu kesme işleminde kolon bazlı olarak resimdeki piksel büyüklük değişimi belirli bir eşik değerinden büyük ise bu alan ilgilenilen alan olarak değerlendirilmeye tabi tutulmuştur. Daha sonra kesilmiş bu resim nesne tespiti için başka bir ağa verilmiştir.

Zhao ve diğ. (2022) yaptıkları çalışmada X-ray görüntülemeye mevcut veri setlerindeki örnekler içerisinde benzer görsel işaretlere sahip olma durumu göz önünde bulundurulmadığı için bu durumları içeren yeni bir veri seti önermişlerdir. Bu veri setinde ayrıca tehlikeli görülen sıvılar da bulunmaktadır. Daha önceki çalışmalarda kullanılan renk, kontör ve dikkat mekanizmasının yerine etiket duyarlı bir mekanizma geliştirmişlerdir. Bu mekanizmada iki nesnenin üst üste binmesi durumunda tahminde hataya neden olabilecek nesneye ait gereksiz bilgilerin etiket bilgisi yardımıyla tahmine katkısı azaltılarak ağırlıklandırılmıştır. Çözüm için kullandıkları derin öğrenme yöntemi Uyarlamalı Eğitim Örnek Seçimi (Adaptive Training Sample Selection, ATSS) ile aynıdır. Aralarındaki tek fark yukarıda bahsedilen etiket duyarlı mekanizmanın ayrı bir dal olarak ResNet50 ve FPN'den elde edilen özellikleri işlemesidir. Son olarak geliştirdikleri bu modeli literatürdeki En Son Başarıyı Temsil eden (State-of-the-Art, SOTA) modeller ile kıyaslamışlardır.

Mery ve diğ. (2022) hazırladıkları makalede çanta taramanın yanı sıra çok sayıda X-ray görüntü çeşitleri üzerinde nesne tespitini tehlikeli resim yansıtma yöntemi kullanarak gerçekleştirmişlerdir. Yapılan sentetik üretimlerde daha önce literatürde farklı kişiler tarafından da kullanılan Beer–Lambert yasasını kullanmışlardır. GDXray veri seti üzerinde üretilen sahte resimleri sadece eğitim aşamasında kullanarak YOLO, SSD ve RetinaNet gibi çeşitli derin öğrenme modellerini eğitmişlerdir.

Liu ve diğ. (2022b) hazırladıkları makalede X-ray görüntüleri üzerinde hafif (lightweight) tehlikeli sıvı tespiti yapmaya çalışmışlardır. Oluşturdukları yöntemde sahte renk resimler kullanmak yerine çift enerji X-ray verilerini kullanarak görüntüleme ve tespit işlemlerini aynı anda doğruluk oranını artırarak gerçekleştirmişlerdir. DLDX (Dangerous Liquid Detection X-ray) adını verdikleri yöntem nesnenin yerinin belirlenmesi, belirlenen bu yer bilgisiyle nesnenin görüntüden çıkartılması ve son adımda sınıflandırması olarak üç aşamadan oluşmaktadır. İlk aşamada çift enerji resimleri üzerinde konum tespiti yapmak için MobileNet, Derinlemesine Evrişim (Depthwise Convolution, DWC) ve Noktasal Evrişimden (Pointwise Convolution, PWC) oluşan

Derin Yönlü Ayrılabilir evrişim yöntemlerini kullanmışlardır. Bu konumlandırma ağında blok yapısı olarak İyileştirilmiş Ters Kalıntı Blok (Improved Inverted Residual Block, IIRS) kullanmışlardır. Bu ağdan çıkan konumlandırma sonuçlarına göre görüntüden çapa kutusu (anchor box) boyutlarını k-ortalama algoritması vasıtasıyla elde etmişlerdir. Daha sonra nesneyi görüntüden çıkararak daha yüksek bir doğruluk elde etmek için dolgulama (padding) işlemine tabi tutup sabit bir boyuta getirmişlerdir. Üçüncü aşamada ise bu özellikleri bir sınıflandırma ağına vermişlerdir. Bu ağda da IIRS blokları ve ayrıca konumlandırma ağından farklı olarak Sıkıştırma ve Uyarma (Squeeze and Excitation) bloğu da kullanarak parametre ve zaman masrafı azaltımı gerçekleştirmişlerdir. Bu ağ yapısının dışında çalışmada yarı otomatik bir yöntem kullanarak veri seti içerisindeki görüntüleri etiketlemişlerdir. Geliştirilen bu yöntemlerin etkinliğini çeşitli deneyler yaparak göstermişlerdir.

Liu ve diğ. (2022a) hazırladıkları makalede X-ray güvenlik görüntülemeye kullanılan derin öğrenme yöntemlerinin performansını veri artırımı ile yükseltmek istemişlerdir. Oluşturdıkları veri artırımı stratejisinde sahte renk X-ray görüntüleri kullanmak yerine ham X-ray verilerini kullanmışlardır. Daha gerçekçi X-ray görüntüleri elde etmek istedikleri DA-PIX adını verdikleri bu yöntemde, veri setindeki gerçek görüntüler kullanılarak WGAN-GP yöntemi ile elde edilen sahte resimler ve gerçek X-ray görüntüleri birleştirme stratejileri sayesinde üst üste binmeleri daha iyi temsil etmişlerdir. Ayrıca yöntemlerinde Roy ve diğ. (2018) tarafından önerilen Sıkıştırma ve Uyarma tabanlı uzaysal ve Kanalsal Dikkat Bloğu (spatial-and-channel attention block, SCAB) içeren SCABXWGAN-GP modelini tasarlayarak kullanmışlardır. Bu sayede kullanılan GAN ağının daha anlamlı bilgilere odaklanarak daha gerçekçi resimler üretmesini sağlamışlardır. Gerçekleştirmiş oldukları deneylerde YOLOV4-tiny modelini DA-PIX kullanarak ve kullanmayarak eğitmiş ve karşılaştırmışlardır.

Shao ve diğ. (2022) hazırladıkları makalede havalimanı güvenliği X-ray görüntülerinde mevcut olan üst üste binme problemini, tehdit nesnelerini vurgulayarak arka plan görüntülerinden ayıran bir yöntemle çözmüşlerdir. İlgili yöntemde Çapraz Aşama Kısmi DarkNet53 Ağı (Cross Stage Partial Dark Network, CSPDarkNet53) uzaysal piramit havuzlama ve yol birleştirme ağı kullanarak yüksek seviye özellikler elde etmişler. Sonraki aşamada bu bilgileri kullanarak ön ve arka planı birbirinden ayırmışlardır. Ayrıca bir dikkat modülü ile birleştirdikleri yöntemi çeşitli veri setleri üzerinde deneyler yaparak kıyaslamışlardır.

2.2.3. Anomali tespiti

Anomali tespiti herhangi bir veri setindeki aykırı örneklerin bulunması işlemidir. X-ray güvenlik konusunda ise saklama, gizleme vb. manalara gelen normalden kayma durumlarıdır (Griffin ve diğ., 2018). X-ray güvenlik görüntülemesinde mevcut normal nesnelerin içerisinde bulunmaması gereken yasaklı nesnelerin gizlenmesi olarak da tanımlanabilir. Burada derin öğrenme yöntemleri vasıtasıyla normal nesnelerin tespitinin yanında bunların içeriklerinin genele ne kadar uyduğu göz önünde bulundurulmaktadır. Yani bir sınıflandırma görevinin yanında sınıflanan maddenin gerçeğe ne kadar uyduğu da göz önünde bulundurulmaktadır.

Andrews ve diğ. (2017) konferans makalelerini otomatik güvenlik görüntüleme konusundaki o zamana kadar literatürde olan yöntemlerin sadece belirli sınıflara ait nesnelerin tespitine odaklanması ve bu tarz incelemenin daha ileri seviye tehlike sınıfları ile karşılaşıldığında (örn. Etkili bir gizleme yöntemiyle saklama) etkisiz kalması nedeniyle hazırlamışlardır. X-ray görüntüsünün birden fazla yamadan oluşturulduğu kargo görüntülemesinde anomali tespitini yama seviyesinde gerçekleştirmeye çalışmışlardır. Oluşturdukları çerçeve, resim temsilleri ve bu temsillere bağlı olarak anomalinin tespiti şeklindedir. Çalışmada çeşitli ön işleme teknikleri ile görüntülerdeki hataları ve gürültüleri giderdikten sonra ilgili görüntü temsillerini yoğunluk tabanlı veya CNN tabanlı olarak çıkarmışlardır. Daha sonra bu temsilleri kullanan rastgele bölünmüş ağaçlar ormanı yöntemi ile elde edilen normal veri bilgisine aykırı olan görüntüleri belirlemişlerdir. Son olarak ilgili çalışma ile yaptıkları deneylerin ön sonuçlarını yayınlamışlardır.

Gaus ve diğ. (2019b) yaptıkları çalışmada havalimanı güvenliği için kullanılan X-ray bagaj görüntülemesi ile anormal eşyaların tespitini gerçekleştirmişlerdir. Çalışmada CNN kullanarak karmaşık X-ray güvenlik görüntüleri üzerinden otomatik anomali tespiti yapmışlardır. Bunun için ikili bir ağ yapısı önermişlerdir. İlgili ağ ilk olarak sıvı ve elektrikli nesneleri tür olarak belirleyip ikinci aşamada anomali varlığını incelemektedir. Çalışmada ilk aşamadaki belirli nesne türlerinin konumlandırmalarının bulunması işleminde bölge tabanlı (R-CNN), maske tabanlı (Mask R-CNN) ve RetinaNet gibi nesne tespit mimarilerindeki son gelişmelerden faydalanmışlardır. İkinci aşama için ise var olan basit CNN yapılarından ve ince elenmiş sınıflandırma kategorileri yaklaşımlarından istifade ederek nesne anomali tespitini iki sınıflı bir problem olarak formüle etmişlerdir (anomali var ve yok). Çalışmanın ilk aşamasında 6 adet nesne çeşidini sınıflandırıp, bu

nesnelerin herhangi bir anomaliye sahip olup olmadığını sonraki adımda tespit etmişlerdir. Yapmış oldukları deneylerde elde ettikleri sonuçlarda gösteriyor ki ilgili görev oldukça zorludur, aynı zamanda gelecek de vaat etmektedir.

2.2.3.1. GAN tabanlı yöntemler

Danışmansız bir derin öğrenme modeli olan GAN tabanlı yöntemlerde iki ağ bütünüleştik kullanılarak bu ağların daha doğru tahminler yapması sağlanmaktadır. Bu ağlardan ilki üretici ağ denilen ağıdır. Bu ağ ile ilgili veri setinin yapay örnekleri aslına uygun olacak şekilde üretilmeye çalışılır. Ayırt edici ağda ise bu sahte örneklerin herhangi birinin gerçek veya sahte olduğu belirlenmeye çalışılır. X-ray güvenlik görüntülemesinde GAN tabanlı yöntemlerin kullanımı genellikle veri artırımı ve anomali tespiti olarak gerçekleştirilmiştir. Anomali tespitinde normal veri durumların dağılımı vb. tespit edilerek buna uygun olmayan anormal örneklerin yakalanması amaçlanmıştır. Aşağıda anomali tespiti için kullanılan GAN tabanlı çalışmalar verilmiştir. Bu çalışmalarda GAN yapıları ile normal örneklerin olasılıksal ve yapısal dağılımları yakalanarak buna uygun olmayan aykırı durumlar tespit edilmeye çalışılmıştır.

Akçay ve diğ. (2018a) hazırladıkları makalede X-ray görüntülemesinde anomali tespiti problemini neredeyse normal resimlerden oluşan bir veri seti kullanarak yeni bir çeşikmeli otomatik kodlayıcı ağ ile eğiterek çözmüşlerdir. Bu sayede resim ve gizli vektör uzayına ait veri dağılımını yakalamaya çalışmışlardır. İlgili yaklaşımda iki kodlayıcı (encoder), bir kod çözücü (decoder) ve bir ayırt edici ağlardan oluşan üç adet alt ağ bulunmaktadır. Oluşturdukları bu yapıyı normal resimler üzerinde eğittikleri için anormal durumların bu yapı ile yeniden inşa edilemeyeceğini varsaymışlardır.

Griffin ve diğ. (2018) hazırladıkları makalede anomali tespitinin X-ray güvenlik görüntülemesindeki önemini ayrıca alandaki çeşitli anomali türlerini anlatmışlar ve bunlardan sadece görünüş ve semantik anomaliler üzerine çalışmışlardır. Görünüş anomalileri, şekil, doku, yoğunluk ile semantik anomaliler için hazırlanan algoritmaları detay vererek anlatmışlardır. Fotoğraflardaki nesne sınıfını belirlemek için kullanılan ön eğitilmiş bir evrişimsel ağdan çıkarılan temsiller ile anomalileri tespit etmişlerdir. Görünüş anomalisi için ağın son havuzlama katmanından, semantik anomalisi için ağın logit katmanından faydalanmışlardır. Normal verideki temsillerin dağılımlarını yüksek boyutlu, tam kovaryans, gauss modelleri kullanarak modellemişlerdir. Ayrıca anomalileri

bu modellere göreceli benzerliklerine göre puanlandırmışlardır. Algoritmalarıyla X-ray koli resimleri üzerinde silah tespiti şeklindeki anomalileri de bulmaya çalışmışlardır.

Dumagpi ve diğ. (2020) hazırladıkları makalede sınıf dengesizliği sorununu azaltmak maksadıyla bir CNN ve SVM sınıflandırıcıyla birlikte GAN tabanlı bir anomali tespit yaklaşımı oluşturmuşlardır. Bu yöntemde çoklu tehdit nesnesi sınıflandırması yapmışlardır. Ayrıca bir adet İki Yönlü Üretici Karşıt Ağı (Bidirectional Generative Adversarial Networks, Bi-GAN) ilgili anomali tespitinde kullanmışlardır. Bi-GAN’da klasik çekişmeli kayıp fonksiyonunun yanı sıra ek bir eğitim amaç fonksiyonu da kullanmışlardır. Hazırladıkları bu ağ üç aşamada eğitmişlerdir. Birinci aşamada sınıflandırıcının doğru pozitif oranını ideal bir eğitim seti üzerinde eğiterek en yükseğe çıkarmışlardır. İkinci aşamada bir adet Bi-GAN eğiterek negatif örneklerin dağılımını öğrenmeye çalışmışlardır. Üçüncü aşamada özellik eşleştirme kayıpları ve yeniden inşa (reconstruction) üzerinde bir SVM eğiterek sert eşiklemeye güçlü bir alternatif oluşturmaya çalışmışlardır. Tespit yapılan normal görüntülerdeki elde edilen ilk sınıflandırma sonuçları uygulanan test seti değerlendirilirken yanlış pozitifleri azaltmak için baskılamaya (suppress) tabi tutulmuşlardır. Gerçek dünya durumlarını yakından yansıtan bir veri kümesi üzerinde yapılan değerlendirmede elde edilen sonuçlar ile, yaklaşımın gelecek vaat ettiğini göstermişlerdir.

2.2.4. Kümeleme

Kümeleme eldeki verilerin belirli sayıda ayrı gruplara ayrılması işlemi olarak tanımlanabilir. Güvenlik görüntülemeye ise resmin içerisinde bulunan arka plan ve nesnelerin belirlenerek birbirinden farklı olarak etiketlenme veya renklendirilmesi sürecidir. Belirlenen bu alt resimler daha sonra farklı bir ağa verilerek sınıflandırma vs. için kullanılabilirler. X-ray güvenlik görüntülemesinde yapılan çalışmalar ilgili resimlerin içerisindeki nesnelerin arka plandan ve diğer nesnelerden ayrılması, daha sonra bu resim parçalarının farklı bir derin öğrenme ağına verilerek sınıflandırılması şeklinde gerçekleştirilmiştir. Bu alanda kümeleme yaparken genellikle sahte renklendirme ile elde edilen RGB (Red Green Blue) renkler kullanılmıştır. Bunun dışında yapılan çalışmalarda kümeleme resim genelinde yapılmıştır.

Bhowmik ve diğ. (2019a) hazırladıkları konferans makalesinde X-ray güvenlik görüntüleri üzerinde anomali tespiti yapmaya çalışmışlardır. Literatürde yapılan daha önceki çalışmalarda anomali tespitinin resmin genelinde veya nesne düzeyinde

yapıldığını tespit etmişlerdir. Resmin içerisinden hemen göze çarpmayan saklı nesnelerde olabileceğini düşünerek resmin belirli bir parçasının anomali içerebileceğini varsaymışlardır. Bundan ilham alarak resmi önce kümeleyerek resmin tamamını ve/veya bir kısmını anomali tespiti için incelemişlerdir. İlgili kümeleme (segmentasyon) stratejilerini hem nesne seviyesinde hem de bileşen altı seviyede ikincil (ilki nesne seviyesinde kümelemede) bir CNN aracılığıyla anomali tespiti yapmada kullanmışlardır. Veri seti olarak ise 14964 adet X-ray görüntüsünden oluşan bir sistemi transfer öğrenme stratejisi ile kullanmışlardır. Anomali olarak ilgili elektronik eşyaların içerisinde metal plakalar, vidalar, bıçak ağızları vb. nesnelerin tespitini yapmışlardır.

Bhowmik ve diğ. (2019b) hazırladıkları makalede elektrikli ve elektronik eşyaların içerisine saklanmış tehlikeli maddelerin tespitini X-ray görüntüleri üzerinden otomatik olarak yapmaya çalışmışlardır. Bu amaçla çeşitli CNN'leri problemin çözümünde kullanmışlardır. Komponent altı seviyede resim üstü segmentasyonu gerçekleştirmişlerdir. Çalışmalarında nesne seviyesinde konum tespiti yapmak için Mask R-CNN ve Faster R-CNN gibi yöntemleri önce nesnelerin tespiti daha sonra segmentasyonu için kullanmışlardır. Nesne üstü segmentasyonu yapmak için ise Basit Doğrusal İteratif Kümeleme adını verdikleri yöntem ile resmi ilk başta eşit boyuttaki kümeler ayırmışlardır. Daha sonra ilk defa kendileri tarafından sunulan uzaklık ölçüsünü kullanmış ve kümelerin birbirleri ile benzerliklerini bu uzaklık ile ölçmüşlerdir. Böylelikle her bir nesnenin üst segmentasyona sahip olmasını sağlamışlardır. Kullanılan yöntemlerin sonuncusu ise tüm çerçeve seviyesinde, nesne veya segmentasyon seviyesinde sınıflandırma yapılmasıdır. Bunun için bilinen ResNet, VGG mimarilerini kullanmışlardır. Yaptıkları deneylerle kullandıkları yöntemlerin kıyaslamasını gerçekleştirmişlerdir.

Liu ve diğ. (2019) hazırladıkları konferans makalesinde X-ray bagaj güvenlik tarama görüntüleri üzerinde gerçek zamanlı çalışan bir nesne tespit algoritması önermişlerdir. İlk olarak X-ray bagaj güvenlik görüntülerinden tespit edilen nesneyi renk bilgisini kullanarak arka plandaki nesnelerden ayıran bir segmentasyon yöntemi önermişlerdir. Daha sonra X-ray görüntüsündeki nesneleri Faster R-CNN kullanarak sınıflandırmış ve konum tespiti yapmışlardır.

Chouai ve diğ. (2020) hazırladıkları makalede güçlü bir öznetelik çıkarıcı mekanizma kullanan çekişmeli otomatik kodlayıcıyı bir derin evrişimli ağ ile birleştiren yeni bir derin öğrenme sistemi önererek, X-ray ile bagaj kontrolünde nesne tespit alanına katkıda bulunmaya çalışmışlardır. Önerilen sistemde görüntüler potansiyel olarak örtüşen

bölgelere ayrılmaktadır. Bu da resimlerin aynı ve farklı türdeki maddelerin üst üste binme durumları da göz önünde bulundurularak organik ve inorganik görüntüler olarak ayrılması ile gerçekleştirilmektedir. Bunun için klasik görüntü işleme yöntemlerinde kullanılan her bir pikselin yalnızca bir alana ait olduğu kümeleme yöntemlerinin yerine her bir pikselin altı sınıftan birine ait olduğu bir kümeleme yöntemini kullanmışlardır. Bu sınıflar organik ve inorganik maddelerin birbirleriyle örtüşmesini de içermektedir (organik/organik, organik/inorganik vs.). Önerilen sistemin üstünlüğünü göstermek amacıyla son çıkan derin öğrenme semantik segmentasyon sistemleri ile karşılaştırmalı bir analiz yapmışlardır. Beş farklı derin öğrenme algoritmasını bu karşılaştırma için kullanmışlardır. Bunlar Tam Bağlı Evrişimsel Ağlar (Fully Convolutional Networks, FCN), Segmentasyon Ağı (Segmentation Network, SegNet), U Ağı (U Network, U-Net), Geri Konvolüsyon Ağı (Deconvolutional Network, DeconvNet) ve Yoğun Bağlantılı Kalıntı Ağı (Residual Network with Dense Connections, RedNet) yöntemleridir. Geliştirdikleri yöntemin bu algoritmalara nazaran başarısını yaptıkları deneyler sonucunda göstermişlerdir.

Yao ve diğ. (2021) hazırladıkları makalede tehlikeli nesnelerin tespiti semantik bölümlenimin (segmentation) bir görevi olarak kabul etmiş ve yasaklanmış nesnelerin otomatik olarak tespiti için evrensel bir model önermişlerdir. Anlamsal bölümleme (semantic segmentation) yanlış sınıflandırma ve zayıf bölümleme doğruluğuna sahip olduğu için geliştirilen model genel anlamsal bölümleme ağına dayalı iki iyileştirmeye sahiptir. İlk olarak yanlış sınıflandırmayı azaltmayı amaçlayarak ağın alıcı alanını genişletmek için, N tipi kodlama yapısı uygulamışlardır. Bu kodlama yöntemi klasik yöntemlerden farklı olarak iki aşamalı aşağı örnekleme (down-sampling) ve bir aşamalı yukarı örnekleme (up-sampling) içermektedir. İkinci olarak ise X-ray güvenlik görüntülerindeki yüzey dokusu eksikliği göz önünde bulundurularak DenseNet'teki öz niteliğin yeniden kullanımı yaklaşımından esinlenerek, bölümleme doğruluğunu iyileştirmek amacıyla sıkı semantik bilgileri yeniden kullanmışlardır. Daha sonra oluşturulan veri seti üzerinde deneyler yapmışlar ve sonuçları yayınlamışlardır.

Ma ve diğ. (2022a) hazırladıkları makalede X-ray güvenlik taraması görüntülemeye CNN tabanlı segmentasyon yöntemlerini incelemişlerdir. Çalışmada kullanılmak üzere çok fazla üst üste binme durumu içeren bir veri seti oluşturmuşlardır. Ardından bu veri setini kullanarak DeepSnake tabanlı bir yöntem ile segmentasyon yapmışlardır. Yöntemin DeepSnake'den farklı olarak her bir vertekse eş davranmayıp ağırlıklandırma yaparak verteks bazlı bir dikkat mekanizmasına sahip olmasını

sağlamışlardır. Yoğun Çakışma Giderici Dikkat Yılan Ağı (Dense De-Overlap Attention Snake, DDoAS) adını verdikleri yöntemi üç modülden oluşturmuşlardır. Sık Yeniden Bindirme Modülü (Dense De-overlap Module, DDoM), Dikkat Deforme Edici Modül (Attention Deforming Module, ADM), ve Birebir Füzyon Modülü (One-to-One Fusion Module, O2OFM). DDoM ile üst üste binme ve arka plan kaynaklı alakasız bilgileri ağırlıklandırma kullanarak filtrelemişlerdir. O2OFM kullanarak kenar bilgilerini korumayı hedeflemişlerdir. ADM ise DeepSnake kullanılarak kontur bilgilerinin ağırlıklı olarak elde edildiği kısımdır. Oluşturdukları bu yöntemin etkinliğini klasik (vanilla) modeller ile karşılaştırmışlardır.

Dumagpi ve Jeong (2021b) hazırladıkları makalede X-ray güvenlik taramasında kullanılan resim seviyesindeki sınıflandırma ve tespit tekniğinin yerine piksel seviyesinde inceleme yapan bir yöntem geliştirmişlerdir. Bu yöntemde nesne tespiti ve segmentasyonunu iki ayrı modül olarak bütünleşik olarak kullanmışlardır. Yöntemde ilk aşamada Faster R-CNN derin öğrenme yöntemi ile nesne tespiti yapmışlardır. Bu aşamada elde edilen resim parçaları kullanılarak ikinci aşamada nesne ve arka plan görüntülerini piksel seviyesinde resim verilerini kullanarak DeepLabV3, Yol Birleştirme Ağı (Path Aggregation Network, PAN), Karşılıklı Dikkat Ağı (Mutual Attention Network, MA-Net), Piramit Sahne Ayırıştırma Ağı (Pyramid Scene Parsing Network, PSPNet), U-Net, FCN gibi yöntemler vasıtasıyla birbirinden ayırmışlardır.

3. MATERYAL VE YÖNTEM

Bu bölümde görüntüleme teknolojileri, X-ray güvenlik görüntülemesi, makine öğrenmesi, yapay sinir ağları, derin öğrenme, derin öğrenme algoritmaları, oluşturulan veri seti, kullanılan metrikler ve performans göstergeleri hakkında bilgiler verilmiştir.

3.1. X-ray Güvenlik Teknolojileri

X-ray güvenlik taraması, özellikle güvenlik öncelikli kamu kurum ve kuruluşları havalimanları, limanlar, alışveriş merkezleri, tren istasyonları gibi tesislerde kullanılan bir güvenlik mekanizmasıdır. Bu tarama, X-ray kullanılarak kişilerin ve eşyaların içindeki cisimleri belirleme amacıyla yapılmaktadır. X-ray, nesnelerin içinden geçerken farklı yoğunlukta olan maddeleri tespit edebilmekte ve bu sayede özellikle tehlikeli veya yasaklı maddeleri tespit etmek için kullanılmaktadır.

X-ray güvenlik taraması genellikle X-ray cihazları kullanılarak yapılır. Kişilerin bagajları, valizleri veya diğer eşyaları X-ray cihazına yerleştirilir ve cihazın içinden geçirilir. Bu süreçte, X-ray ışınları cisimlerin içine girer, farklı yoğunlukta maddelerden geçerken emilime uğrar ve dedektörler tarafından bu emilim algılanır. Operatörler bu görüntüleri inceleyerek potansiyel tehditleri veya yasaklı maddeleri tespit etmeye çalışırlar. Bu şekilde, güvenlik personelleri tehlikeli veya yasaklı maddelerin taşınmasını engellemek için müdahalede bulunabilirler. X-ray güvenlik taraması, genellikle güvenliği artırmak ve riskleri azaltmak için kullanılan önemli bir güvenlik önlemidir. Burada kullanılan teknolojilerin birçok çeşidi vardır. Bunlardan en fazla kullanılan BT'dir. Şekil 3.1'de birkaç adet 2-b ve 3-b X-ray görüntüleri örnek olarak verilmiştir.



Şekil 3.1 Örnek X-ray resimleri

Silah ve patlayıcı türevi yasaklı maddelerin tespiti için X-ray, gamma ışını, elektromanyetik alan ve milimetrik dalgalar gibi birçok teknik uygulanmıştır. Aşağıda bu tezde kullanılan X-ray görüntüleme teknolojilerinden en popüler olan geleneksel iletim, çift enerjili, dağılımsal ve 3 boyutlu görüntüleme yöntemleri hakkında bilgiler verilmiştir (Singh ve Singh, 2003).

Standart iletim yönteminde X-ray cihazları ile yansıtılan ışın demetinden çantanın her bir bölgesinden ne kadar X-ray fotonu yok olduğu ölçülür. Burada X-ray ışın demetinin nasıl yok olduğunun bir önemi yoktur. Bundan dolayı atomsal enine kesit (cross-section) iletim resminin herhangi bir konumundaki azalmayı ve toplam X-ray etkileşimli enine kesiti (foto elektriksel ve dağılımsal enine kesitin toplamı) ifade eder (Singh ve Singh, 2003).

Çift enerjili X-ray, ilk güvenlik sistemleri silah tespiti için yüksek enerjili X-ray kullanıyorlardı. 100 kV gibi yüksek enerji seviyelerinde emilen enerji öncelikle maddenin yoğunluğuna bağlıdır. Yoğunluk arttıkça nesne tarafından emilen enerjide artar bu da ilgili nesnenin görüntüsünün daha koyu olmasına neden olur. Silah gibi metal eşyalar çok koyu bir görüntüye sahip olurlar ancak bu yoğunluğu yüksek maddenin arkasında, altında kalan maddelerin görüntüsünde üst üste binmelerden ötürü sorunlar oluşmaktadır. Bu problemi çözmek için bagaj iki farklı enerji seviyesinde taranır (düşük enerji 80 kV civarında), düşük enerji seviyesinde enerji emilimi maddenin etkin (effective) atom numarası ve maddenin kalınlığına bağlıdır. Bu şekilde iki farklı enerji seviyesi kullanan sistemlere çift enerjili sistemler denilir. Bu teknolojiye ait farklı teknikler bulunmaktadır. X-ray kaynağının girdi enerjisinin değiştiği , enerjinin X-ray algılayıcısında filtrelendiği, farklı spektral tepkilerdeki çoklu sensörlerin kullanıldığı vb. olarak sıralanabilir (Singh ve Singh, 2003).

Dağılımsal görüntüleme, patlayıcı maddeler tipik olarak tespit edilmelerini zorlaştıran yaygın zararsız malzemelerle karıştırılır. Plastik patlayıcıların iki özelliği, X-ray ışınları ile etkileşimleri açısından onları benzersiz kılar. İlk olarak, düşük atom sayılarına sahip elementlerden oluşurlar. İkincisi ise, genel kullanım plastiklerinden %30-50 daha yüksek ve tipik paketlenmiş giysilerden yaklaşık beş ila sekiz kat daha fazla fiziksel yoğunluğa sahiptirler. Çift enerjili yöntemler bu özelliklerden birincisini kullanmaya çalışırken, dağıtımsal görüntüleme plastik patlayıcıların hem düşük Z hem de yüksek yoğunluk özelliklerini kullanır. Bu, dağıtımsal görüntüleme tekniklerini daha spesifik hale getirir (Singh ve Singh, 2003).

Bu yöntemde görüntü verileri, sırasıyla geri dağılma ve ileri dağılma görüntüleri olarak adlandırılan saçılmış X-ray enerjilerinden toplanırlar. Bunlar sırasıyla X-ray kaynağına doğru geri yansıtılan dağılmış X-ray enerjisi veya taranan nesnenin içinden ileri doğru geçen X-ray ışık enerjileridir. Dağılım görüntülerinde nesne üzerindeki ışın demeti boyunca her bir konumunda görüntüye dağılım miktarı eklenir. İlgili miktar konuma ulaşan X-ray fotonlarının sayısına, o konumdaki elektron yoğunluğuna, dağılım kesitine ve saçılan fotonların çantadan çıkarken maruz kaldığı zayıflamaya bağlıdır. Bu sayede alüminyum ve plastik gibi aynı iletim karakteristiğine sahip iki madde bu özelliklerine rağmen birbirinden oldukça farklı dağılımsal görüntü kümeleri oluştururlar (Singh ve Singh, 2003).

3 boyutlu görüntüleme teknolojileri sıklıkla kullanılan X-ray tabanlı yöntemlerdendir. Bu teknolojinin bilgisayarlı tomografi, stereoskopik tomografi, çok kaynaklı görüntüleme ve ikiz ortogonal görüntüleme gibi türleri en bilinenleridir (Singh ve Singh, 2003).

Bilgisayarlı tomografi ilk olarak tıbbi görüntüleme uygulamalarında kullanılmıştır. Bir nesneden geçen bir X-ray ışını etkin atom numarasının, yoğunluğunun ve kalınlığının bir fonksiyonudur. Belirli bir X-ray ışını yolu için doğrusal zayıflama katsayısı, yoldaki her bir ögenin zayıflama katsayılarının toplamıdır. BT X-ray ışını zayıflama katsayıları matrisini yeniden oluşturarak nesnenin kesit görüntülerini üretir. Bu kesit görüntüleri nesnenin 3 boyutlu görüntülerinin oluşturulmasında kullanılır. Son amaç ise nesnenin yoğunluk ve etkin atom numarasının belirlenmesidir. Bu da aşağıda anlatılan şekilde gerçekleştirilir. İlk olarak, hacimsel olarak işlenmiş görüntüde yeniden yapılandırma algoritması, her hacim elemanı için zayıflama katsayısını belirler. İkinci olarak tarama ekipmanı geometrisinden ötürü hacim elemanı boyutuna ilişkin bilginin malumatıyla, zayıflama katsayısı atom numarası ve yoğunluğun doğrudan bir fonksiyonu olarak haritalanır. Bu iki bilinmeyen nicelik verir. İki farklı enerjide ölçüm yaparak atom numarası ve yoğunluğun hesaplamasında kullanılan iki bilinmeyenli iki adet denklem oluşturur. Bu sayede hacim elemanları Z_e ve yoğunluklarına göre haritalanabilmekte ve bu değişkenlerin korelasyonu ile hem özellik hem de malzeme ayrımı sağlayabilmektedirler (Singh ve Singh, 2003).

Çok kaynaklı/algılayıcı görüntüleme ise bir diğer 3 boyutlu görüntüleme teknolojisidir ve bu sistemlerde farklı sayıda X-ray kaynakları ve algılayıcılar kullanılır. Örneğin Benjamin ve Prakoonwit (1997) 15 yelpaze ışın kaynağının kullanımını tartışmışlardır. Bu yaklaşımın ana zorluğu ise sistemin yüksek maliyeti, mekanik

ekipmanın karmaşıklığı ve kolimasyon (koşutlama-collimation) hizalamasında karşılaşılan zorluktur. (Singh ve Singh, 2003)

İkiz ortogonal görüntülemede bir X-ray kaynağı ve doğrusal diziler çifti kullanarak iki adet ortogonal resim oluşturmaktadır (Singh ve Singh, 2003).

Stereoskopik görüntülemede ise düz-tarama (line-scan) ekipmanı kullanılarak 3D modelleme yapılmaktadır (Singh ve Singh, 2003)

Görüntüleme teknolojilerindeki son gelişmelerle birlikte havalimanlarındaki bagaj/koli tarama işlemlerinde çift enerjili BT tarayıcıların kullanımını kolaylaştırmıştır. Bu tarayıcılardan elde edilen resim parçaları kullanılarak tıbbi görüntüleme kullanılanlara benzer 3 boyutlu hacimli resimler inşa edilebilmektedir (Flitton ve diğ., 2013).

3.2. X-ray Güvenlik Görüntülemesi

X-Ray görüntüleri üzerinde makine öğrenmesi ve görüntü işleme kullanarak tehlikeli madde tespit uygulamaları havalimanlarında güvenlik riskinin en aza indirgenmesi maksadıyla yolcuların yanında veya bagajlarında taşımaları yasaklı olan maddelerin 3-b veya 2-b X-Ray görüntüleri vasıtasıyla tespiti olarak tanımlanabilir (Mery ve diğ., 2013). Bu uygulamalar genellikle bagaj kontrolünü gerçekleştiren görevliye yardım veya süreci otomatikleştirme maksadıyla kullanılabilir.

Keşfedildiği ilk zamanlardan itibaren X-ray çok farklı amaçlarla kullanılmıştır. Bunlardan en sık kullanılanlardan birisi de X-ray cihazının çeşitli bina ve kuruluşlarda kapı ve giriş noktalarında güvenlik taraması için kullanılmasıdır. Burada kullanılan cihazlar paket, bavul, koli, çanta vb. eşyaların taranması ve içerisinde bulunan eşyaların X-ray ışınını soğurma kapasitelerine bağlı olarak cihaza bağlı veya bütünleşik olan bir bilgisayar ekranına ilgili görüntülerin yansıtılması şeklinde çalışır. Yansıtılan bu görüntü maddelerin yoğunluk ve atom numaralarına göre sahte renklendirme adı verilen bir yöntemle ekrana yansıtılır. Bu görüntüler doğal optik resimlerden oldukça farklıdır. Görüntüler oluşturulurken X-ray ışınlarına tabi tutulduğu için yansıyan görüntüde kaynaktan gelen üst üste binmiş eşyalara dair şeffaf gölge katmanlarının bilgileri de bulunmaktadır (Liu ve diğ., 2022a). İlgili görüntüler bir operatör tarafından değerlendirilerek yasaklı maddeler tespit edilmeye çalışılır. Ancak yapılan bu işlem zaman darlığı, iş yoğunluğu, uzman personel eksikliği gibi nedenlerden dolayı verimli ve güvenli olmamaktadır. Kontrolleri gerçekleştiren görevlilerin dikkatlerini sürekli bu

ekranda tutmaları ve dağıtmamaları gerekmektedir. Bu ise oldukça zor bir iştir. Bu yüzden böyle zahmet gerektiren işlemlerin daha az hata ile daha verimli yapılabilmesi için yeni otomatik yöntemler araştırılmaktadır.

3.3. Makine Öğrenmesi ve Yapay Sinir Ağları

İnsanın tecrübelerinden öğrenmesi sürecinden esinlenen makine öğrenmesi, çeşitli metotlarla bilgisayarlara veri şeklinde tecrübelerin verilmesi ve bunları kullanan öğrenme algoritmalarının geliştirmesi ile yeni örnekler geldiğinde ilgili algoritmaların tecrübelerini kullanarak akıllı tahminler yapması olarak tanımlanabilir (Zhou, 2021). Makine öğrenmesi probleme özel eğitim verisi ile analitik model inşası ve problem çözümünün otomatikleştirilmesi ile sistemlerin öğrenme kapasitelerini tanımlar. Derin öğrenme ise yapay sinir ağlarına dayalı bir makine öğrenmesi yöntemidir (Janiesch ve diğ., 2021).


Yapay sinir ağları insan beyninin geliştirilen fiziksel modelinin çalışma prensibinin taklit edilmesi amacıyla McCulloch ve Pitts (1943) tarafından ortaya atılan ilk yöntemlerin geliştirilmesiyle ortaya çıkmıştır (Janiesch ve diğ., 2021). Bu ilk yöntem bir Turing makinesi şeklinde oluşturularak AND, OR, NOT gibi problemlerin çözümünde kullanılmıştır (Alom ve diğ., 2018). Rosenblatt (1958) tarafından yapılan çalışmada ise ilk perceptron oluşturularak bununla eğer problem temsil edilebiliyorsa öğrenme yapılabildiği gösterilmiştir. Minsky ve Papert (1969) tarafından sonraki süreçte eleştirilen perceptron ve onun yetenekleri özellikle XOR gibi problemlerin çözümünde yaşadığı problemler nedeniyle kendisine ait akademik araştırmaya olan yönelimi azaltmıştır (Berkeley, 1997; Alom ve diğ., 2018). Sonraki dönemlerde azalan bu ilgi Ackley ve diğ. (1985) tarafından önerilen geriye yayılım algoritmasının tanıtılmasıyla beraber göstermiş olduğu kapasite artırımını sonucu tersine dönmüş ve sonraki dönemlerde bir çok alanda bir çok problemin çözümünde kullanılmıştır (Alom ve diğ., 2018). Bu alanlardan birisi de görüntü işlemedir. İlk olarak LeCun ve diğ. (1998) tarafından geliştirilen evrişimsel (convolution) yöntem belge tanıma problemine başarıyla uygulanmıştır. Daha sonra bu yöntem Krizhevsky ve diğ. (2012) tarafından geliştirilerek, AlexNet adıyla daha büyük veri setlerine uygulanmıştır. Diğer yöntemlerin aksine performansını artırmayı sürdürebilmiş bu da başarısının daha iyi anlaşılmasını sağlamıştır. Bundan sonra çeşitli alanlarda yapılan çalışmalarda diğer yöntemleri gölgede bırakmıştır.

3.4. Derin Öğrenme ve Diğer Kavramlar

Derin öğrenme yukarıda da bahsedildiği gibi klasik yapay sinir ağlarının katman ve düğüm olarak oldukça genişletilmesiyle oluşturulmuş bir makine öğrenmesi tekniğidir. Sürücüsüz arabalar, yüz tanıma gibi görüntü işleme tabanlı uygulamalarda oldukça sıklıkla başvurulmaktadır. Literatürde farklı problemler için farklı mimari yapılara sahip birçok derin öğrenme tekniği önerilmekte ve kullanılmaktadır. Evrişimli (Evrişimsel) Sinir Ağları, Kısıtlanmış Boltzmann Makineleri, Otomatik Kodlayıcı (Autoencoder) ve Seyrek Kodlama (Sparse Coding) olmak üzere çok sayıda farklı türü bulunmaktadır (Guo vd. 2016). Sonraki kısımda bu tezde sınıflandırma maksadıyla kullanılan modellerin atası olan evrişimli sinir ağlarından ve onun yapısını oluşturan kavramlardan bahsedilmiştir.

3.4.1. Evrişimsel sinir ağı

Evrişimsel Sinir Ağları birçok katmanın güçlü bir şekilde eğitildiği önde gelen derin öğrenme tekniklerinden biridir. Oldukça etkili bir yöntemdir ve farklı bilgisayarlı görü uygulamalarında sıklıkla kullanılmaktadır (Guo ve diğ., 2016). Yapay sinir ağları gibi evrişimsel sinir ağları da biyolojiden ilham almıştır. Basit ve karmaşık hücrelerin dalgali katmanlarından oluşan beyindeki görsel korteks, mimarilerinin esin kaynağıdır (Rawat ve Wang, 2017). Geleneksel bir CNN'e ait akış şeması Şekil 3.2'de gösterilmiştir.



Şekil 3.2. Basit evrişimsel kökenli sınıflandırıcı

Genelde bir CNN üç ana katmandan oluşur. Bunlar evrişim katmanı, havuzlama katmanı, tam bağlı katmanlardır. Her bir katman farklı bir rol üstlenir. Eğitimde ise ileri

besleme ve geri besleme olmak üzere iki aşama mevcuttur. İleri beslemenin ana amacı girdi resmini mevcut parametreler (ağırlık, eğim, vs.) ile her katmanda temsil etmektir. Daha sonra tahmini çıktı kaynak gerçek etiketler ile kullanılarak kayıp maliyeti hesaplanır. İkincil olarak hesaplanan bu kayıp maliyeti taban alınarak geri besleme aşamasında her bir parametrenin zincir kuralıyla gradyanları(eğimleri) hesaplanır. Tüm parametreler gradyanlar baz alınarak güncellenirler ve sonraki ileri besleme aşaması için hazırlanırlar. İleri ve geri beslemenin yeterli sayıda tekrarlanmasından sonra ağırlık eğitimi durdurulabilir (Guo ve diğ., 2016).


3.4.2. Evrişim katmanı

Evrişim katmanı özellik çıkarıcı gibi hizmet eder ve girdi resimlerinin özellik temsilini öğrenir. Evrişimsel katmanlardaki nöronlar özellik haritalarını oluştururlar. Özellik haritasındaki her bir nöron bazen filtre yığını olarak da adlandırılan önceki katmandaki komşu nöronlarla birbirine eğitilebilir ağırlıklar kümesi vasıtasıyla bağlanmış algılayıcı alanlara sahiptirler. Girdiler öğrenilmiş ağırlık değerleri kullanılarak yeni bir özellik haritası hesaplamak maksadıyla evrişim işlemine tabi tutulurlar. Evrişim sonuçları doğrusal olmayan bir aktivasyon (etkinleşme) fonksiyonuna gönderilir. Bir özellik haritasındaki tüm nöronların eşit olacak şekilde kısıtlanmış ağırlıkları vardır. Ancak aynı evrişim katmanı içindeki farklı özellik haritalarının farklı ağırlıkları vardır, böylece her konumda birkaç özellik elde edilebilir (Rawat ve Wang, 2017). Daha resmi olarak, k . çıktı özelliği haritası Y_k , Eşitlik 3.1’de verildiği şekilde hesaplanabilir:

$$Y_k = f(W_k * x) \quad (3.1)$$

Girdi resmi x ile, k . özellik haritası ile bağlantılı evrişim filtresi W_k ile temsil edilmiştir. Evrişim işlemi $*$ sembolü ile gösterilmiştir ve 2 boyutludur. $f()$ doğrusal olmayan aktivasyon fonksiyonunu temsil eder. Doğrusal olmayan aktivasyon fonksiyonu doğrusal olmayan özelliklerin çıkarımına imkân verir. Geleneksel olarak sigmoid ve hiperbolik tanjant fonksiyonu kullanılmaktaydı. Artık düzeltilmiş doğrusal birim manasına gelen ReLU fonksiyonu popülerleşmiştir. ReLU’nun başarısı ve popülerleşmesi derin evrişim ağlarının etkinliğinin artırılması için yeni aktivasyon fonksiyonlarının geliştirilmesi ve uygulanmasına odaklanan araştırma alanının


açılmasına sebep olmuştur (Rawat ve Wang, 2017). Şekil 3.3'te evrişim katmanlarından kullanılan filtreleme işlemi gösterilmiştir.



Şekil 3.3. Filtreleme işlemi

3.4.3. Havuzlama katmanı

Genellikle bir havuzlama katmanı bir evrişim katmanını takip eder ve özellik haritasının boyutunun ve ağ parametrelerinin azaltılması maksadıyla kullanılır. Evrişim katmanına benzer olarak havuzlama katmanı da dönüşüme karşı değişmezdir. Çünkü hesaplama esnasında komşu pikselleri de hesaba katmaktadır. Ortalama havuzlama ve maksimum havuzlama en sık kullanılan türleridir (Rawat ve Wang, 2017). Şekil 3.4'te bir maksimum havuzlama örneği gösterilmiştir.



Şekil 3.4. Maksimum havuzlama

Şekil. 3.4'te havuzlama 8x8 bir özellik haritası için çıktı haritasını 4x4'e düşürür. Maksimum haritalama operatörü 2x2 boyutunda ve 2 adım büyüklüğüne sahiptir (Guo ve diğ., 2016). Önceleri ortalama havuzlama yöntemi daha fazla kullanılmaktaydı ancak

sonraki çalışmalarda maksimum havuzlama yöntemi tercih edilmiştir. Maksimum havuzlama algılayıcı alandaki en büyük elemanı Eşitlik 3.2'deki gibi seçmektedir (Rawat ve Wang, 2017).

$$Y_{kij} = \max_{(p,q) \in k_{ij}} x_{kpq} \quad (3.2)$$


Havuzlama işleminin çıktısı olan k . özellik vektörü Y_{kij} ile gösterilmiştir. X_{kpq} ise k i j havuzlama bölgesinin kapsadığı (p, q) konumundaki elemanı temsil etmektedir (Rawat ve Wang, 2017).

Havuzlama katmanları bu üç katman arasında üzerinde en fazla araştırma yapılan katmandır. Havuzlama katmanı ile alakalı her biri farklı bir amaç güden üç bilinen yöntem mevcuttur. Bunlar sırasıyla stokastik havuzlama, uzaysal piramit havuzlama, def-havuzlama (deformation constrained pooling) (Guo ve diğ., 2016). Bunların dışında literatürde farklı havuzlama teknikleri önerilmeye devam etmektedir.

3.4.4. Tam bağlı ağlar

Ağ boyunca ilerlerken daha fazla soyut özellik temsili elde edebilmek için genelde birkaç evrişimsel ve havuzlama katmanı art arda yerleştirilir. Bu katmanları takip eden tam bağlı ağ katmanı bu özellik temsillerini yorumlar ve üst seviye muhakeme işlevini gerçekleştirir. Sınıflandırma problemleri için softmax işlevini kullanmak standarttır. Ancak evvelki başarılar radyal temel fonksiyonlar (radial basis functions) tarafından gerçekleştirilmiştir. Evrişimsel kulenin tepesindeki sınıflandırıcıda softmaks işleminin yerine bir destek karar makinesi (SVM) kullanımının bazı araştırmacılar tarafından daha fazla sınıflandırma başarısı getirdiği görülmüştür. Bu şekilde evrişimsel bir ağın tepesinde farklı bir sınıflandırıcı kullanıp başarısının kıyaslanması hala ileri araştırma gerektirmektedir (Rawat ve Wang, 2017).

Şekil. 3.5'te bir havuzlama işlemin takip eden tam bağlı ağ yapısı gösterilmiştir.



Şekil 3.5. Tam bağlı ağ yapısı

Tam bağlı ağlar geleneksel sinir ağları gibi çalışırlar ve bir Evrişimsel Sinir Ağındaki parametrelerin %90'ını içerirler. Sınıflandırma maksadıyla yapay sinir ağının önceden belirlenmiş uzunluktaki bir vektöre ileri beslenmesi işlemine imkân verirler (Guo ve diğ., 2016).

Bu katmanların en büyük dezavantajı ise çok fazla parametre içermeleri nedeniyle eğitim esnasında çok fazla hesaplama işlemi gerektirmeleridir. Bu nedenle sık kullanılan bir yöntem bu katmanların kaldırılması veya bağlantılarının belirli bir yöntemle azaltılmasıdır. Örneğin GoogLeNet tam bağlı bir ağ yerine seyrek bağlı bir mimari kullanarak hesaplama masrafını sabit hale getirmiştir (Guo ve diğ., 2016).


3.5. Sınıflandırmada Kullanılan Derin Öğrenme Modelleri

Daha önceki kısımlarda yer alan makine öğrenmesi, derin öğrenme başlıkları altında anlatıldığı gibi derin öğrenme yöntemleri yapay sinir ağlarından evrilmiştir. Çok çeşitli türleri olmasına rağmen burada anlatılanlar sınıflandırma problemi için tezde kullanılan evrişimsel yöntemlerdir. Bu yöntemlerin ana hatları ile tanıtımı yapılmıştır. Ayrıca ilgili yöntemlerin mimari özellikleri katman sayıları gibi bilgiler verilmiştir.

3.5.1. ResNet

ResNet, kalıntı sinir ağı anlamına gelir ve 2015 yılında Microsoft Research araştırmacıları tarafından, derin ağların yakınsamaya başlaması sırasında doğruluğunun doymuşlaşması ve hızlı bir şekilde azalması şeklinde gerçekleşen ve ağın derinliğinin sonucunda oluşan, bozulma sorununu çözmek amacıyla önerilmiştir (He ve diğ., 2016).

ResNet modelinde çözüm için, literatürde önceki dönemlerde araştırılan kısaltma bağlantıları (shortcut connections) esin kaynağı olmuştur. Benzerlerine Inception ağındaki (Szegedy ve diğ., 2015) ilgili katmanların yapısında , otoyol ağlarında (highway networks) (Srivastava ve diğ., 2015a; Srivastava ve diğ., 2015b) kapı fonksiyonunda (Hochreiter, 1997) ve Çok katmanlı Perceptron ağlarının eğitilmesinde kullanılan birkaç yöntem örnek verilebilir (He ve diğ., 2016). Kısaltma bağlantıları bir katmanın aktivasyonlarının bir veya daha fazla katman atlayarak birleştirilmesi şeklinde gerçekleştirilmektedir. Bazı katmanların atlanması, kalıntı blokların oluşmasını sağlar ve kalıntı blokların üst üste eklenmesiyle ResNet oluşturulur. Şekil 3.6, kısaltma bağlantıları tarafından gerçekleştirilen $F(x)+x$ formülasyonunu göstermektedir.



Şekil 3.6. Kalıntı bloğu (Residual block)


ResNet klasik mimariden ayrımını gösteren matematiksel denklem aşağıda verilmiştir. Burada ilk Eşitlik 3.3 klasik mimaride de kullanılan orijinal yapıdır. İkinci Eşitlik 3.4 ise kalıntı bloğunda kullanılan denklemdir.

$$H(x) = f(X) \quad (3.3)$$

$$H(x) = f(X) + x \quad (3.4)$$

Kısaltmaların hem kimlik eşleme işlemini gerçekleştirmeleri hem de kaybolan gradyan sorununu azaltmaları sonucu, önceki katmanların çıktıları, üst üste eklenen katmanların çıktılarına eklenerek daha derin ağların eğitilmesine ve verimliliğin artırılmasına olanak sağlamıştır. VGG-19'dan esinlenilerek oluşturulan ilk ResNet versiyonu, 34 katmandan oluşmaktadır. Bu katmanlar, 3x3 filtrelerle 32 evrişim katmanı, bir maksimum havuzlama katmanı ve bir ortalama havuzlama katmanından oluşurlar.

Ayrıca, ResNet-34 mimarisinde iki tasarım kuralı bulunur. İlki, her katmandaki filtre sayısı ve çıktı özellik haritasının boyutlarının eşit olması şeklinde gerçekleştirilen. İkincisi ise, özellik haritasının boyutunun yarıya indirilmesi durumunda, katman başına zaman karmaşıklığını korumak için filtre sayısının iki kat artırılması şeklinde gerçekleştirilen kuraldır. ResNet-50 ise, Şekil 3.6'da gösterilen kalıntı blok, katmanları eğitmek için gereken zaman masrafından dolayı 1×1 evrişimler eklenerek darboğaz (bottleneck) tasarımıyla güncellenmiştir ve bu Şekil 3.7'de gösterilmiştir. Darboğaz, parametre ve matris çarpımlarının sayısını azaltır ve her katmanın çok daha hızlı eğitilmesini sağlar.



Şekil 3.7. Kalıntı bloğun hesaplama maliyetinin düşürülmesi için güncellenmiş hali

Ayrıca literatürde bulunan ve bu tez çalışmasında kullanılan farklı katman sayılarına sahip ResNet mimarileri Çizelge 3.1.'de verilmiştir.

Çizelge 3.1. Literatürdeki ResNet mimarilerinin yapısı

Katman adı	Çıktı Boyutu	18-Katman	34-Katman	50-Katman	101-Katman	152-Katman
Evr1	112x112	7x7, 64, adım 2				
Evr2_x	56x56	3x3 maks havuz, adım 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
Evr3_x	28x28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
Evr4_x	14x14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
Evr5_x	7x7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1x1	Ort. havuz, TB, softmaks				

ResNet101 veya ResNet152 gibi daha derin kalıntı ağıları, daha fazla 3-katmanlı darboğaz bloğu kullanılarak oluşturulur. Ağ derinliğinin artması doğruluğu iyileştirir ve

ayrıca buna rağmen VGG-16/19 ağlarından daha düşük karmaşıklığa sahiptirler (He ve diğ., 2016; Wu ve diğ., 2019). Çizelge 3.1’de gösterildiği gibi Her bir Evrişim (Convolution, Evr) katmanı 2 veya daha fazla 3x3 veya 1x1 katmanların arka arkaya eklenmesiyle oluşmaktadır. İlk katmanda 7x7 filtreden sonra 3x3’lük bir Maksimum Havuzlama katmanı (Maximum pooling, Maks. Hav.) bulunmaktadır. Son katmanda ise softmaks içeren bir Tam Bağlı (Fully Connected, TB) ağ katmanı Ortalama Havuzlama (Average Pooling, Ort. Hav.) ile kullanılmaktadır.

3.5.2. DarkNet

DarkNet, YOLOv2 ve YOLOv3’ün arka planında kullanılan tek atışlık (single-shot) bir derin öğrenme mimarisidir. DarkNet-19 (Redmon ve Farhadi, 2017) ve DarkNet-53 (Redmon ve Farhadi, 2018), sırasıyla 19 ve 53 evrişim katmanına sahiptir. DarkNet-53’teki büyük sayıda evrişim katmanına ek olarak, bozulmayı aşmak için kalıntı bağlantıları uygulanmıştır. Çizelge 3.2 DarkNet19’un katman düzenini göstermektedir.

Çizelge 3.2. DarkNet-19 mimarisi

Katman	Filtre	Boyut/Adım	Çıktı
Evrişim	32	3x3	224x224
Maks. Hav.		2x2/2	112x112
Evrişim	64	3x3	112x112
Maks. Hav.		2x2/2	56x56
Evrişim	128	3x3	56x56
Evrişim	64	1x1	56x56
Evrişim	128	3x3	56x56
Maks. Havuz.		2x2/2	28x28
Evrişim	256	3x3	28x28
Evrişim	128	1x1	28x28
Evrişim	256	3x3	28x28
Maks. Hav.		2x2/2	14x14
Evrişim	512	3x3	14x14
Evrişim	256	1x1	14x14
Evrişim	512	3x3	14x14
Evrişim	256	1x1	14x14
Evrişim	512	3x3	14x14
Maks. Hav.		2x2/2	7x7
Evrişim	1024	3x3	7x7
Evrişim	512	1x1	7x7
Evrişim	1024	3x3	7x7
Evrişim	512	1x1	7x7
Evrişim	1024	3x3	7x7
Evrişim	1000	1x1	7x7
Ort. Hav.		Global	1000
Softmaks			

DarkNet yukarıda da bahsedildiği gibi YOLO modellerinde sınıflandırıcı olarak tasarlanmıştır. Önceki çalışmalar göz önünde bulundurularak VGG'ye benzer yapıda çoğunlukla 3 x 3 filtrelerin kullanıldığı ve her havuzlamadan sonra filtre sayısının iki katına çıktığı bir yapıda tasarlanmıştır. "Network in Network" (NIN) çalışmasını takip ederek tahmin aşamasında global ortalama havuzlama ve ayrıca 3x3 filtreler arasında özellik temsilini sıkıştırmak için 1x1 filtreler kullanmışlardır (Redmon ve Farhadi, 2017). Aşırı öğrenme sorunu Yığın Normalleştirme (Batch Normalization, YN) ve her DarkNet evrişim katmanından sonra eklenen seyreltme işlemleri ile çözülmüştür. DarkNet-53, DarkNet-19'dan daha büyük bir ağıdır ancak daha hızlıdır (Redmon ve Farhadi, 2018). DarkNet mimarisi, 1x, 2x, 4x ve 8x gibi beş farklı kalıntı bloğuna sahiptir (Şekil 3.11'de dikdörtgenle gösterilmiştir.). İlk kalıntı bloğu 32 filtre ile başlar ve her kalıntı grubunda iki katına çıkar. Her blok, bazı kısayol bağlantıları olan 1x1 filtreli evrişim katmanlarından sonra gelen 3x3 filtreli evrişim katmanlarına sahiptir. Ayrıca bu blokların her birinin bir atlama (skip) bağlantısı vardır. Her gruptan önce, özellik haritalarının uzaysal boyutunu azaltan bir de evrişim katmanı bulunur. Özellik haritalarının boyutunu azaltmak, düşük seviye özelliklerin kaybını önlemeye ve nesne tespiti için faydalı olan konumsal bilgileri kodlamaya yardımcı olur. Çizelge 3.3 DarkNet53'ün katman düzenini göstermektedir.

Çizelge 3.3. DarkNet-53 mimarisi


	Tür	Filtre	Boyut/Adım	Çıktı
	Evrişim	32	3x3	256x256
	Evrişim	64	3x3/2	128x128
1x	Evrişim	32	1x1	
	Evrişim	64	3x3	
	Kalıntı			128x128
	Evrişim	128	3x3/2	64x64
2x	Evrişim	64	1x1	
	Evrişim	128	3x3	
	Kalıntı			64x64
	Evrişim	256	3x3/2	32x32
8x	Evrişim	128	1x1	
	Evrişim	256	3x3	
	Kalıntı			32x32
	Evrişim	512	3x3/2	16x16
8x	Evrişim	256	1x1	
	Evrişim	512	3x3	
	Kalıntı			16x16
	Evrişim	1024	3x3/2	8x8
4x	Evrişim	512	1x1	
	Evrişim	1024	3x3	
	Kalıntı			8x8
	Ort. Hav.		Global	
	TB		1000	
	Softmaks			

DarkNet-53, saniye başına düşen kayan nokta işlemlerini diğer ağlardan daha yüksek oranda gerçekleştirir (Redmon ve Farhadi, 2018). Dolayısıyla GPU'yu daha iyi kullanarak değerlendirmeyi de daha hızlı yapar.

3.5.3. InceptionV3


GoogLeNet, 22 derin katman (havuzlama katmanları dahil 27 katman) içeren bir derin evrişimli sinir ağıdır. GoogLeNet, Google tarafından 2015'te ImageNet Large-Scale Visual Recognition Challenge 2014 (ILSVRC14)'de sınıflandırma ve tespit için önerilen NIN çalışmasından etkilenecek geliştirilen toplam dokuz Inception modülünü içerir (Szegedy ve diğ., 2015). Bu Inception modülü ile, ağı hem derinliği hem de genişliği artırılmaktadır. Bu durum GoogLeNet'i evrişimli sinir ağı modellerinde genişlik kavramını tanıtan ilk model yapmaktadır (Szegedy ve diğ., 2015). Inception mimarisi, bir evrişim ağı içindeki optimal yerel seyrek yapının yaklaşık bir modelini oluşturmayı

amaçlar. Bundan dolayı 1x1, 3x3 ve 5x5 filtreleri ve 3x3 maksimum havuzlamayı paralel olarak gerçekleştiren Inception modüllerinden oluşur. Bu işlem Şekil 3.8(a)'da gösterildiği gibi evrişim katmanlarında gerçekleştirilir. Bununla birlikte modelin işlem karmaşıklığı, büyük çıktı boyutu ve paralel işlemlerden kaynaklanan yüksek parametre sayısı gibi bazı sorunları vardır. Bu sorunları aşmak için Şekil 3.8(b)'de gösterildiği gibi paralel Inception evrişim katmanlarından önce 1x1 evrişim katmanları eklenmiştir. Bu 1x1 evrişimler boyut azaltılması amacıyla kullanılmaktadır. İlgili mimarinin temel faydaları, hesaplama karmaşıklığında artışın önlenmesi ve her aşamada birim sayısında önemli bir artışa izin vermesidir (Szegedy ve diğ., 2015).




Orijinal Inception modeline ek olarak Szegedy ve diğ. (2016) yaptıkları çalışmada performansı artırmak için Inceptionv2 ve Inceptionv3 adında iki güncellenmiş versiyon önermişlerdir. Inceptionv2 modelinde, Inceptionv1'e göre doğruluğu artırmak ve hesaplama karmaşıklığını azaltmak için çeşitli iyileştirmeler yapılmıştır. Bu iyileştirmeler (Szegedy ve diğ., 2016) çalışmasında verildiği üzere şunları içermektedir:

- i. Derin öğrenme modelleri evrişim katmanları girdinin boyutunu çok miktarda değiştirmedeğinde bilgi kaybı daha az olduğundan daha iyi performans göstermektedirler. Bu yüzden temsili darboğazdan kaçınılmalıdır (Szegedy ve diğ., 2016; Poudel, 2019).
- ii. Bir evrişimli ağda, kare başına aktivasyon artırılarak ağ daha hızlı eğitilebilir. Bu kurala uygun tasarlanan modül Şekil 3.9'da verilmiştir.



Şekil 3.9. İkinci kurala uygun olarak genişletilmiş filtre yığını


iii. Uzaysal birleştirme, daha düşük boyutlu gömmeler kullanılarak yapılabilir. Yani büyük boyutlu evrişim işlemleri yerine daha küçük boyutlu evrişim işlemleri art arda yapılır. Örneğin 5x5'lik işlem iki adet 3x3 evrişime dönüştürülerek daha az masrafla benzer performansta yapılır. Bu kurala uygun tasarlanan modül Şekil 3.10'da verilmiştir.



Şekil 3.10. Üçüncü kuralda belirtilen 5x5 evrişim yerine 3x3 kullanılması ile oluşan modül

iv. Ağın genişliği ve derinliği arasındaki denge korunmalıdır. Yani daha önceki Inceptionv1 de ağ daha derindi bu yüzden hesaplama karmaşıklığı sabit olması için ağ daha geniş olmalıdır.

Yukarıda açıklanan yükseltmeler uygulandıktan sonra Inception modülünün çarpınlara ayırma işleminden sonraki sürümü Şekil 3.11'de verilmiştir.



Şekil 3.11. Inception modülü $n \times n$ 'lik evrişimin çarpanlara ayrılması sonrasında elde edilen

InceptionV3'ü InceptionV2'den ayıran yalnızca evrişim katmanları değildir, ayrıca yardımcı sınıflandırıcı olacak şekilde yığın normalleştirilmeye tabi tutulan bir tamamen bağlı bir katmanın eklenmesi de vardır. Çizelge 3.4'te çalışmada kullanılan Inceptionv3'e ait katmansal mimari gösterilmiştir.


Çizelge 3.4. Inceptionv3 mimarisi

Tür	Boyut/Adım veya arkasını bul	Giriş boyutu
Evrişim	$3 \times 3/2$	$299 \times 299 \times 3$
Evrişim	$3 \times 3/1$	$149 \times 149 \times 32$
Evrişim dolgulu	$3 \times 3/1$	$147 \times 147 \times 32$
Havuzlama	$3 \times 3/2$	$147 \times 147 \times 64$
Evrişim	$3 \times 3/1$	$73 \times 73 \times 64$
Evrişim	$3 \times 3/2$	$71 \times 71 \times 80$
Evrişim	$3 \times 3/1$	$35 \times 35 \times 192$
$3 \times$ Inception	Şekil 3.10 gibi	$35 \times 35 \times 288$
$5 \times$ Inception	Şekil 3.11 gibi	$17 \times 17 \times 768$
$2 \times$ Inception	Şekil 3.9 gibi	$8 \times 8 \times 1280$
Havuzlama	8×8	$8 \times 8 \times 2048$
Doğrusal	logit	$1 \times 1 \times 2048$
Softmax	sınıflandırıcı	$1 \times 1 \times 1000$

3.5.4. EfficientNet

Derin öğrenme modellerinin başarısı ağ yapısındaki katman sayısı ve katmanlardaki nöron sayısı vb. birçok faktörden etkilenmektedir. Bu parametrelerin en iyi kombinasyonunu belirlemek için ise kesin bir formül yoktur. Optimum veya optimuma en yakın olanı bulmak için Tan ve Le (2019) tarafından EfficientNet adlı bir yöntem geliştirilmiştir. Genişlik, derinlik ve çözünürlük gibi üç farklı parametreyi

rastgele ayarlamak yerine, oluşturdıkları matematiksel bir formülle daha dengeli bir şekilde değiştirmeye çalışmışlardır. Makalede kullanılan farklı ölçeklendirme işlemleri Şekil 3.12’de gösterilmiştir. Ayrıca hesaplamada kullanılan Eşitlikler Eşitlik 3.5- 3.9’da verilmiştir.



Şekil 3.12 EfficientNet derin öğrenme modelindeki ölçeklendirme işlemleri
(a) temel, (b) genişletme, (c) derinleştirme, (d) çözünürlük ölçekleme, (e) bileşik ölçekleme

$$\text{derinlik: } d = \alpha^\emptyset \quad (3.5)$$

$$\text{genişlik: } w = \beta^\emptyset \quad (3.6)$$

$$\text{çözünürlük: } r = \gamma^\emptyset \quad (3.7)$$

$$s. t. \alpha. \beta^2. \gamma^2. \approx 2 \quad (3.8)$$

$$\alpha \geq 1, \beta \geq 1, \gamma \geq 1 \quad (3.9)$$

Şekilde verilen genişlik, bir katmanda bulunan nöron sayısını (ağın yatay olarak genişliği), derinlik toplam katman sayısını (dikey olarak ağın boyutunu), çözünürlük ise giriş görüntüsünün boyutunu göstermektedir. Şekilde bu işlemlerin temel ağa uygulanmasıyla ağın ölçeklendirilmesi gösterilmiştir. Temel mimarilerini, yukarıda belirtilen parametreleri ve deneylerde buldukları katsayıları kullanarak, yedi farklı ölçekte modeli önerdikleri bileşik ölçekleme yöntemiyle oluşturmuşlardır. Daha büyük, daha geniş ağlar veya daha yüksek çözünürlüklü giriş görüntüleri kullanan ağlar daha başarılı olsalar da belirli bir ağ boyutundan sonra doyuma ulaşırlar. EfficientNet kullanılarak ağın en makul ve başarılı sürümü bulunmaya çalışılır. Ağın ölçeklenmesi hesaplama maliyetini de beraberinde getirir. EfficientNet B0-B7 arasında ölçekleme yöntemi ve performans testleri (Tan ve Le, 2019)’te raporlanmıştır. Çalışmada kullanılan


ölçeklendirme parametreleri ve ağ boyutlarını belirlerken kullandıkları formül yukarıda Eşitlik 3.5-3.9’da verilmiştir. Mimari boyutu, denklemdaki $\emptyset$ ile ihtiyaçlara göre kontrol edilmektedir. α , β , γ sabitleri küçük bir ızgara araması (grid search) ile bulunmuştur. Deneylerinin sonucunda bu sabitler için buldukları ideal değerleri paylaşmışlardır. Son olarak ise, herhangi bir evrimsel ağ, EfficientNet kullanılarak temel ağ olarak seçilerek ölçeklendirilebilir. Burada, ilgili ağ B0 olarak belirtilmiştir. Ardından, yukarıdaki formülle ölçeklendirilerek en başarılı ağ bulunmuştur. Hesaplama maliyetinin önüne geçmek amacıyla tez kapsamında EfficientNetB0 versiyonu kullanılmış olup mimarisi Çizelge 3.5’te verilmiştir. Burada Taşınabilir Dönüştürülmüş Darboğaz Bloğu (Mobile inverted bottleneck Block, MBEvr) ana inşaat bloğu olarak kullanılmıştır.

Çizelge 3.5. EfficientNet-B0 temel ağı – her bir satır $\langle \hat{H}_i x \hat{W}_i \rangle$ giriş çözünürlüklü ve $\hat{C}_i$ çıktı sayılı $\hat{L}_i$ katmanlı i aşamasını tanımlar

Aşama i	Operatör $\hat{F}_i$	Çözünürlük $\hat{H}_i x \hat{W}_i$	#Kanallar $\hat{C}_i$	#Katmanlar $\hat{L}_i$
1	Evr3x3	224 x 224	32	1
2	MBEvr1, k3x3	112 x 112	16	1
3	MBEvr6, k3x3	112 x 112	24	2
4	MBEvr6, k5x5	56 x 56	40	2
5	MBEvr6, k3x3	28 x 28	80	3
6	MBEvr6, k5x5	28 x 28	112	3
7	MBEvr6, k5x5	14 x 14	192	4
8	MBEvr6, k3x3	7 x 7	320	1
9	Evr1x1 & Havuzlama & TB	7 x 7	1280	1

3.5.5. ShuffleNet


ShuffleNet, Zhang ve diğ. (2018) tarafından kısıtlı hesaplama imkanına sahip olan mobil cihazlar düşünülerek özel olarak tasarlanmıştır. İlgili makalede hafif (light-weight) ağların hesaplama maliyetinden ötürü sınırlı sayıda özellik kanalı karşılayabilmeleri nedeniyle noktasal grup evrişimi (pointwise group convolution) ve kanal karıştırma (channel shuffle) adı verilen işlemler ile işlem yükü (FLOP) azaltılmaya çalışılmıştır (Ma ve diğ., 2018). ShuffleNet modelinin ve Grup evrişimi (GEvr) işleminin nasıl gerçekleştirildiği Şekil 3.13’te gösterilmiştir.



Şekil 3.13. Evrişim işlemi için kanal diagramları

a) Çapraz konuşmasız grup evrişimi b) Çapraz konuşmalı grup evrişimi c) Karıştırılmış (Shuffled) kanallar

Çalışmada kullanılan grup evrişimi ilk olarak AlexNet'te (Krizhevsky ve diğ., 2012) kullanılan ve derin öğrenme modelinin farklı GPU'larda paralel olarak çalıştırıldığı yöntemde de kullanılmıştır. Bunun dışında daha sonra diğer çalışmalarda da kullanılmıştır. ShuffleNet mimarisinde ise grup evrişimi karıştırma işlemi ile beraber kullanılarak yeni bir yöntem olarak tanıtılmıştır. Şekil 3.13'in (a) kısmında gösterildiği gibi grup evrişiminde gelen girdi değeri birbirinden bağımsız olarak farklı GPU'larda evrişim vb. işlemlere tabi tutulmaktadır. Bu durumda elde edilen çıktıda sadece ilgili gruptaki filtreler sonuca etki etmektedir. Ancak bazı çıktılarda farklı gruptaki filtrelerin etkisi önemli olabilmektedir. Bu sebeple ilgili çıktı bir sonraki evrişim işlemine uygulanırken her bir gruba bir parçası katkı verecek şekilde karıştırılarak performans artırılmaya çalışılmaktadır. Ancak bu işlem oldukça masraflı olabilmektedir. Bunu azaltmak için ShuffleNet mimarisinde yeni bir yöntem geliştirilmiştir. Burada bir önceki evrişim katmanından gelen g adet grubun $g \times n$ adet çıktısı karıştırma işleminde önce (g, n) olarak yeniden boyutlandırılır. Ardından bu matris transpoze ve düzleştirme (flatten) işlemlerine tabi tutularak (b)'dekine benzer bir karışma işlemi daha az masrafla elde edilir. ShuffleNet'in en büyük avantajı benzer sınıflandırma başarılarını çok daha az karmaşıklığa sahip modeller ile elde edebilmesidir. Ayrıca ShuffleNet ve ResNet darboğaz birimlerinin farkı Şekil 3.14'te gösterilmiştir.



Şekil 3.14 ShuffleNet birimleri

- a) Derinlemesine evrişimli darboğaz birimi (DTEvr)
 b) Noktasal grup evrişimli (GEvr) ve kanal karıştırmalı ShuffleNet birimi
 c) Adım=2 olan ShuffleNet birimi

Şekil 3.14'te gösterilen, çeşitli ResNet mimarilerinde de bulunan derinlemesine ayrılabilir evrişimlerde (depthwise separable convolution) kullanılan darboğaz işlemi a'da ve eş değeri olan ShuffleNet birimi ise b'de verilmiştir. Sonuncu da ise girdi boyutu düşürülmek istendiği zamanlarda ShuffleNet'de kullanılan birim yapısı gösterilmiştir. Çizelge 3.6'da ise tez çalışmasında kullanılan ShuffleNet modelinin katmansal mimarisi verilmiştir.

Çizelge 3.6. ShuffleNet mimarisi

Katman	Çıktı boyutu	KBoyutu	Adım	Tekrar	$g = 1$	Çıktı Kanal (g)		grubu	$g = 8$
						$g = 2$	$g = 3$	$g = 4$	
Resim	224×224				3	3	3	3	3
Evr1	112×112	3×3	2	1	24	24	24	24	24
MaksHav	56×56	3×3	2						
Aşama2	28×28		2	1	144	200	240	272	384
	28×28		1	3	144	200	240	272	384
Aşama3	14×14		2	1	288	400	480	544	768
	14×14		1	7	288	400	480	544	768
Aşama5	7×7		2	1	576	800	960	1088	1536
	7×7		1	3	576	800	960	1088	1536
GlobalHav	1×1	7×7							
TB					1000	1000	1000	1000	1000
Karmaşıklık					143M	140M	137M	133M	137M

3.5.6. MobileNet


MobileNet mimarisi evrişimsel katmanların içerdiği hesaplama masrafını derinlemesine ayrılabilir filtreler ile azaltarak ilgili ağların daha az hesaplama kabiliyetine sahip cihazlarda da kullanılabilmesi ve eğitilebilmesini sağlamaya çalışmıştır (Howard ve diğ., 2017). Bunu ise klasik evrişim işleminde bütünleşik olarak yapılan matris çarpımı yerine eş değer bir işlem olarak ilgili süreci derinlemesine (derinlik bazlı) (depth-wise) ve noktasal (nokta bazlı) (point-wise) olarak ikiye ayırarak başarmaktadır. Bu işlemde özellikle nokta bazlı çarpım aşamasında 1x1 filtre kullandığı için hesaplama maliyeti oldukça düşmektedir. İlgili çalışmada verildiği gibi standart bir evrişim işleminin hesaplama maliyeti Eşitlik 3.10-3.12'deki gibi hesaplanabilir.

$$\text{Hesaplama Masrafı} = D_K \times D_K \times M \times N \times D_F \times D_F \quad (3.10)$$

$$\text{Derinlik -Bazlı (kanal - bazlı) Masraf} = D_K \times D_K \times M \times D_F \times D_F \quad (3.11)$$

$$\text{Derinlik -Bazlı Ayrılabilir Evrişim Masrafı} = D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F \quad (3.12)$$

Burada M girdi katmanının kanal sayısı, N çıktı katmanının kanal sayısı, $D_K \times D_K$ filtre boyutları ve $D_F \times D_F$ ise özellik haritası boyutudur. Burada yapılacak işlem sayısı ilgili işlemdeki $D_K \times D_K \times M \times N$ adet filtre ve $D_F \times D_F$ boyutunun çarpılması ile bulunabilir. MobileNet'te M'den N' e ulaşmak için standart bir evrişim işleminde matris çarpımı yapmak yerine ilgili işlem sırasıyla derinlemesine ve noktasal evrişim işlemleri ile değiştirilir. Derinlemesine evrişimde tek bir filtre katman bazlı (channel_wise) olarak uygulanır. Bu nedenle girdide M olan katman sayısı kadar işlem yapılmış olur. Ancak bu filtrelerden çıktıda N adet bulunmaktadır. Bu yüzden ilgili katman sayısını N adete çıkarmak ve filtreleri lineer olarak birleştirmek için noktasal işlem kullanılır. Burada 1x1 filtre kullanıldığı için $D_K \times D_K$ olan masraf filtre boyutları 1 olduğu için 1'e düşer ve noktasal işlemi için masraf $M \times N \times D_F \times D_F$ olur. İlgili iki işlemin toplam masrafı klasik evrişim işlemine göre oldukça azdır. Bu süreç genel şekliyle Şekil 3.15'te verilmiştir.



Şekil 3.15. Derinlik bazlı ayrılabilir evrişim basamakları (Howard ve diğ., 2017)


Şekil 3.15'te gösterildiği gibi bir filtre önce tek bir filtre boyunca işlem yapar (M adet filtre olduğu için M kez). Daha sonra birbirinden bağımsız olan bu değerler 1x1 filtre ile birleştirilir (boyutu N olduğu için N kez). Çizelge 3.7'de ise tezde kullanılan MobileNet mimarisinin katmansal gösterimi ilgili çalışmadaki şekliyle verilmiştir. Burada Derinlik Bazlı (Depth Wise, db) evrişim katmanları kullanılmıştır. Adım (Step, a) boyu ise boyut küçültme durumunun varlığına bağlı olarak 1 veya 2 olarak verilmiştir.

Çizelge 3.7. MobileNet mimarisi

Tür / Adım	Filtre Boyut	Giriş Boyutu
Evr / a2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Evr db / a1	$3 \times 3 \times 32$ db	$112 \times 112 \times 32$
Evr / a1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Evr db / a2	$3 \times 3 \times 64$ db	$112 \times 112 \times 64$
Evr / a1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Evr db / a1	$3 \times 3 \times 128$ db	$56 \times 56 \times 128$
Evr / a1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Evr dw / a2	$3 \times 3 \times 128$ db	$56 \times 56 \times 128$
Evr / a1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Evr dw / a1	$3 \times 3 \times 256$ db	$28 \times 28 \times 256$
Evr / a1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Evr dw / a2	$3 \times 3 \times 256$ db	$28 \times 28 \times 256$
Evr / a1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5×	Evr db / a1	$3 \times 3 \times 512$ db
	Evr / a1	$1 \times 1 \times 512 \times 512$
Evr db / a2	$3 \times 3 \times 512$ db	$14 \times 14 \times 512$
Evr / a1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Evr db / a2	$3 \times 3 \times 1024$ db	$7 \times 7 \times 1024$
Evr / a1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Ort Hav / a1	Havuz 7×7	$7 \times 7 \times 1024$
TB / a1	1024×1000	$1 \times 1 \times 1024$
Softmaks / a1	Sınıflandırıcı	$1 \times 1 \times 1000$

3.5.7. DenseNet


Kaybolan gradyan probleminin üstesinden gelmek ve derin sinir ağlarında özelliklerin yeniden kullanımını geliştirmek için Huang ve diğ. (2017) tarafından tasarlanmıştır. Mimarisi her katmanın ileri beslemeli bir şekilde diğer her katmana doğrudan bağlandığı yoğun (dense) bağlantıların kullanılmasıyla elde edilir. Şekil 3.16'da gösterilen yoğun bloklarda, tüm katmanlar eşleşen özellik haritası boyutlarıyla birbirine bağlanır ve her katman, özellik haritalarını sonraki katmanlara yayarken önceki katmanlardan ek girdiler alır ve sürekli bir bilgi akışı korunur. Bu özellikler DenseNet'i verimli ve güçlü bir evrimsel sinir ağı türü haline getirmektedir ve çeşitli bilgisayarla görme görevlerinde dikkate değer bir performans göstermiştir (Huang ve diğ., 2017).



Şekil 3.16. DenseNet mimarisindeki yoğun bloklar (dense blocks)

DenseNet'i oluşturan yoğun bloklar birkaç katmandan oluşmaktadırlar. Her bir katmanda k adet özellik (feature) bulunmaktadır. Buradaki k değeri ağın büyüme oranı olarak adlandırılmaktadır. DenseNet'in ayırt edici özelliği her bir katman girişinin aynı yoğun bloktaki önceki katmanların tüm özellik haritalarının birleşimi olmasıdır. Her bir katmanda yığın normalleştirme, ReLU gibi çeşitli dönüşümler uygulanmaktadır (Huang ve diğ., 2018).

Şekil 3.16'da görülen yapı tek bir yoğun bloğa aittir. Birden fazla yoğun blok Inception ağlarında olduğu gibi art arda bir araya gelerek aşağıda verilen Şekil. 3.17.'deki gibi bir yapı oluşturarak derin ağ yapısını oluşturur. Bu bloklar arasında kalan geçiş katmanı olarak adlandırılan evrişim ve havuzlamadan oluşan yapı ile özellik haritasının boyutu değiştirilmektedir.



Şekil 3.17. Üç katmanlı bir DenseNet

Yoğun bağlanım adı verilen ve DenseNet'in ana yapısını oluşturan yapı daha önce önerilmiş ResNet yapısındaki kalıntı ağı yapısının sadece tek bir önceki katman yerine tüm katmanları kapsayacak şekilde artırılmasıyla oluşturulur. Bu sayede katmanlar arası bilgi akışı artırılmaktadır. Aşağıda ilgili denklem Eşitlik 3.13'te verilmiştir.

$$x^l = H^l([x^0, x^1, \dots, x^{l-1}]) \quad (3.13)$$


Klasik CNN'lerde birbirini izleyen evrişim ve havuzlama işlemleri aracılığıyla ağ, uzaysal değişmezliğe (spatial invariance) ulaşır ve üst katmanlarda kaba anlamsal özellikler elde eder. Ancak, ince görüntü detayları ağın üst katmanlarında kaybolma eğilimindedir. Daha önce de bahsedildiği gibi DenseNet içerisinde en son katman dahi kendisinden önceki tüm katmanlara ait bilgilere erişebilmektedir. Bu sayede model daha kompakt ve aşırı öğrenmeye daha az açıktır (Zhu ve Newsam, 2017). Çizelge 3.8'de ise sıklıkla kullanılan çeşitli DenseNet mimarileri verilmiştir.

Çizelge 3.8. DenseNet Mimarisi

Katmanlar	Çıktı Boyutu	DenseNet-121($k = 32$)	DenseNet-169($k = 32$)	DenseNet-201($k = 32$)	DenseNet-161($k = 48$)
Evrışım	112×112	7×7 evr., adım 2			
Havuzlama	56×56	1	1	1	1
Yoğun Blok (1)	56×56	1×1 evr. $\times 6$ 3×3 evr.	1×1 evr. $\times 6$ 3×3 evr.	1×1 evr. $\times 6$ 3×3 evr.	1×1 evr. $\times 6$ 3×3 evr.
Geçiş Katmanı (1)	56×56	1×1 evr.			
	28×28	1	1	1	1
Yoğun Blok (2)	28×28	1×1 evr. $\times 12$ 3×3 evr.	1×1 evr. $\times 12$ 3×3 evr.	1×1 evr. $\times 12$ 3×3 evr.	1×1 evr. $\times 12$ 3×3 evr.
Geçiş Katmanı (2)	28×28	1×1 evr.			
	14×14	1	1	1	1
Yoğun Blok (3)	14×14	1×1 evr. $\times 24$ 3×3 evr.	1×1 evr. $\times 32$ 3×3 evr.	1×1 evr. $\times 48$ 3×3 evr.	1×1 evr. $\times 36$ 3×3 evr.
Geçiş Katmanı (3)	14×14	1×1 evr.			
	7×7	1	1	1	1
Yoğun Blok (4)	7×7	1×1 evr. $\times 16$ 3×3 evr.	1×1 evr. $\times 32$ 3×3 evr.	1×1 evr. $\times 32$ 3×3 evr.	1×1 evr. $\times 24$ 3×3 evr.
Sınıflandırma Katmanı	1×1	7×7 global ortalama havuz			
		1000B tam bağlı, softmax			

3.5.8. Xception

Chollet (2017) tarafından 2017 yılında ortaya atılan bir mimaridir. "Xception", Extreme Inception, yani Inception mimarisinin bir uzantısı anlamına gelmektedir. Uzaysal filtreler yerine, derinlemesine ayrılabilir evrişimler, uzaysal ve kanal bazlı filtrelemeyi ayırmak amacıyla tasarlanmıştır ve bu da CNN'lerin performansını artırmaktadır. Şekil 3.18'de gösterildiği gibi, evrişim işlemini içerir, burada her kanalda bağımsız olarak evrişim yapılır ve noktasal konvolüsyonu, kanallar arası etkileşim için 1x1 evrişimin uygulandığı bir aşamayı ifade eder (Chollet, 2017).




Şekil 3.18. Xception modülü

Derinlemesine ayrılabilir bir evrişime genellikle “Ayrılabilir Evrişim” denir. Bu katman, hesaplama maliyetlerinde daha verimli olması beklenen klasik evrişim katmanına bir alternatif olarak önerilmiştir. Orijinal derinlemesine ayrılabilir evrişim katmanı, derinlik açısından ayrılabilir evrişimden sonra noktasal evrişimin çalıştırıldığı, derinlemesine ayrılabilir bir evrişim yöntemidir. Xception modelinde ise modifiye edilmiş derinlemesine çıkarılabilir bir evrişim katmanı kullanılır. Burada temel değişim 1x1 evrişimin yani noktasal evrişimin her bir kanaldan önce (Inceptionda en sonda) derinlemesine evrişim uygulanmadan önce gerçekleştirilmesidir (Shaheed ve diğ., 2022).

Oluşturdukları mimaride ana fikir bir evrişim ağındaki özellik haritalarındaki kanallar arası korelasyon (cross-channel correlation) ve uzaysal korelasyon (spatial correlations) haritalarının tamamıyla ayrıştırılabilir yapılmasına dayanmaktadır. 36

evrişim katmanından oluşan ağ yapısı 3 kısımdan oluşmaktadır. İlk giriş akımı adını verdikleri kısımdır. Ardından 8 kez tekrar eden orta akımdan çıkış akımına ulaşır. Tam bağlı ağ yapısı ve logistik regresyon ile sınıflandırmaya tabi tutulur. Şekil 3.19'da Xception ağ mimarisi verilmiştir.



Şekil 3.19. Xception ağ mimarisi

3.6. RWN

Çok katmanlı ağların tasarımında karşılaşılan ve kesin bir çözümü bulunmayan katman sayılarının veya katmandaki nöron sayılarının belirlenmesi, bunların ayarları, ilk ağırlık değerlerinin atanması ve eğitimde ne kadar veriye ihtiyaç duyulacağı gibi sorunlar nedeniyle literatürde bu değerlerin çeşitli şekilde belirlenmesine yönelik çalışmalar olmuştur. Bunlardan birisi de Aşırı Öğrenme Makinesi (Extreme Learning Machine, ELM) adlı yöntemdir. ELM veya rastgele ağırlıklı ağlar (RWN) olarak adlandırabileceğimiz bu yöntemin kökenleri Pao ve Takefuji (1992) ve Schmidt ve diğ. (1992) gibi rastgele ağırlıklı ağlar belirlemeye yönelik çalışmalara, ayrıca (Lowe ve Broomhead, 1988; Saunders ve diğ., 1998) gibi konuda farklı açılardan daha önce yapılmış çeşitli makalelere dayanmaktadır. RWN ile bir yapay sinir ağının eğitiminde yapay sinir ağının yapısal olarak giriş, gizli katman ve çıkış katmanı olmak üzere 3

katmanlı bir yapı olması gerekir (Huang ve diğ., 2004; 2006). RWN ile yapay sinir ağının eğitimi için iteratif bir süreç bulunmamaktadır ve eğitim süreci geleneksel hatanın geri yayılım algoritmasına göre oldukça hızlıdır. RWN yapay sinir ağının gizli katmanı ile çıkış katmanı arasındaki ağırlıklarını analitik bir yöntem ile tek adımda hesaplar. Eğitim süreci tek adımda hesaplandığından dolayı aşırı hızlı bir eğitim sürecine sahiptir. Bir ileri beslemeli yapay sinir ağında gizli katmanda N tane nöron olduğu ve aktivasyon fonksiyonunun $g(x)$ olduğu kabul edildiğinde M adet (x_i, t_i) eğitim örneği için çıkış hesabı Eşitlik 3.14 ile yapılır.

$$O_j = \sum_{i=1}^N \beta_i g_i(x_j) = \sum_{i=1}^N \beta_i g_i(w_i \cdot x_j + b_i), \quad j = 1..M \quad (3.14)$$

Eşitlik 3.14'te $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ giriş vektörü, $t_i = [t_{i1}, t_{i2}, \dots, t_{in}]^T \in R^m$ giriş vektöründeki her bir eğitim örneğinin etiketi, $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ i. gizli düğüm ile giriş düğümü arasındaki ağırlık vektörü, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ i. gizli düğüm ile çıkış düğümü arasındaki ağırlık vektörü ve b_i gizli katman düğümünün bias değeridir. Bu bağlamda Eşitlik 3.15 aşağıdaki şekilde tekrar yazılabilir.

$$H\beta = T \quad (3.15)$$

$$H = (w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_N \cdot x_1 + b_N) \\ \vdots & \vdots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_N \cdot x_N + b_N) \end{bmatrix} \quad (3.16)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix} \text{ ve } T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} \quad (3.17)$$

Eşitlik 3.15 ve 3.16'daki H, yapay sinir ağının gizli katman çıkış matrisidir. İleri beslemeli yapay sinir ağını eğitmek için spesifik β'_i ve w'_i ağırlıkları gradyan tabanlı öğrenme algoritmaları ile Eşitlik 3.18 ile hesaplanmaktadır.

$$\|H(w'_1, \dots, w'_N, b'_1, \dots, b'_N)\beta - T\| = \min_{w_i, b_i, \beta} \|(w_1, \dots, w_N, b_1, \dots, b_N, x_1, \dots, x_N)\beta - T\| \quad (3.18)$$

RWN’de giriş katmanı ile gizli katman arasındaki ağırlıklar rastgele atandıktan sonra gizli katman ile çıkış katmanı arasındaki ağırlıklar (β) Eşitlik 3.19 ile hesaplanabilir.

$$\beta = H^+T \quad (3.19)$$


Eşitlik 3.19’daki H^+ Moore-Penrose genelleştirilmiş ters matristir. RWN’de eğitim örnek sayısı ile gizli katmandaki nöron sayısı eşit olduğunda H kare matris olduğundan Moore-Penrose yaklaşımına ihtiyaç olmamasına rağmen genellikle eğitim örnek sayısı gizli katmandaki nöron sayısından fazla olduğundan dolayı matrisinin tersinin alınabilmesi için Moore-Penrose yaklaşımı kullanılmaktadır. RWN’nin eğitim sürecinin neden çok hızlı olduğu da Eşitlik 3.18 ile verilen ağırlıkların belirlenebilmesi için çevrimsel yöntemler kullanılırken Eşitlik 3.19’da tek adımda ağırlıkların belirlenmesi ile ortaya çıkmaktadır.

3.7. Veri Seti

Tezin ve projenin bütününde dizüstü bilgisayarların içerisine saklanmış devrelerin tespit edilmesi için derin öğrenme yöntemleri geliştirilmesi üzerinde durulmuştur. Bu bağlamda derin öğrenme yöntemlerinin eğitilebilmesi ve test edilebilmesi için veri setine ihtiyaç duyulmuştur. Bu ihtiyacı karşılamak adına tez ile beraber yürütülen projenin ilgili iş paketinde üç görev tanımlanmıştır.


- i) Örnek devrelerin ve/veya elemanlarının oluşturulması
- ii) İkinci el bilgisayarların satın alınması
- iii) Bu devrelerin bilgisayarlara gizlenerek X-ray görüntülerinin alınması

Örnek devre olarak piyasada kolaylıkla bulunabilen Arduino kartları tercih edilmiştir. Yeni dizüstü bilgisayarların fiyatlarının yüksek olması, çok sayıda farklı dizüstü bilgisayara ihtiyaç duyulması sebebiyle piyasadan ikinci el dizüstü bilgisayarlar satın alınmıştır. Konya Havalimanı Mülki İdare Amirliğinden alınan izinle havaalanındaki X-ray cihazları kullanılarak 60 dizüstü bilgisayarın farklı konfigürasyonlarda X-ray görüntüleri elde edilmiştir. Farklı açılardan alınmış dizüstü bilgisayarların X-ray görüntüleri Şekil 3.20’de verilmiştir. Şekil 3.20’de kırmızı dikdörtgenler içine alınmış alanlarda bilgisayar anakartına ait olmayan gizlenmiş devreler bulunmaktadır ve dikdörtgenler elle çizilmiştir.



Şekil 3.20. Farklı açılardan elde edilmiş dizüstü bilgisayarların X-ray görüntüleri

Şekilde görüldüğü üzere dizüstü bilgisayarın anakartı ve üzerine yerleştirilmiş devrenin görüntüsü plastik bir kutu içerisinde (havalimanlarında standart uygulama) yer almaktadır. Bu veri işleme açısından anlamlı bir veri olmadığından ön işleme aşamasında plastik kutu görüntüsü eşikleme yöntemi ile yok edilmiş ve bütün X-ray görüntülerinde açık sarı olarak görünen gereksiz alan bilgisi görüntülerden silinmiştir ve Şekil 3.21’de dizüstü bilgisayarın temizlenmiş bir X-ray görüntüsü verilmiştir.



Şekil 3.21. Temizlenmiş ve segmente edilmiş X-ray görüntüsü

Tez kapsamında başvurulanan Tübitak 1001 Projesinin iş paketinde de tanımlandığı takvime uygun olarak yaklaşık 5 aylık bir süreçte toplam 6395 X-ray görüntüsü çekilmiştir. Bunlardan 2545 tanesinde gizlenmiş devre bulunmakta 3850 tanesinde

bulunmamaktadır. Gerçek dünyada tehlikeli durum örneklerinin olmayan durumlara oranı oldukça azdır. İlgili oranı belirlemek ise oldukça zordur. Ayrıca bu oranda oluşturulan veri seti dengesiz bir set olacaktır. Bu da eğitilecek modellerde tehlikesizlik durumuna karşı bir meyile sebep verecektir. Bu durumu engellemek maksadıyla oluşturulan veri seti içerisindeki devre olmayan görüntü sayısı 2549'a indirilmiş ve toplam 5094 X-ray görüntüsü deneylerde kullanılmıştır. Problem bir sınıflandırma problemi olarak ele alındığından dolayı derin öğrenme yöntemleriyle eğitim ve test sürecinde görüntülerin etiketlerinin de bulunması gereklidir. 5094 X-ray görüntüsü normal veya anormal olarak işaretlenmiş ve farklı klasörlerde tutulmuştur. Literatür analizinde ve kullanılan derin öğrenme mimarilerinde giriş boyutları farklı olduğundan dolayı görüntülerin giriş boyutu ile uygun olması amacıyla tüm görüntülere her bir derin öğrenme algoritması için yeniden boyutlandırma yapılmıştır. Her ne kadar X-ray cihazının yürüyen bandının eni (görüntüde sütun sayısı) 704 piksel ile ifade edilmiş olsa da boyu, bant sürekli bir akış davranışında olduğundan dolayı farklılık göstermektedir (Bu durum Şekil 3.18'da arka planının beyaz olmasından dolayı tam olarak görülmemektedir). Bundan dolayı Şekil 3.19 ile arka plan ve nesne görüntüsü segmente edilmiş ve temiz görüntü elde edilmiştir. Elde edilen bu görüntü ise her bir derin öğrenme yönteminin girişi için uygun hale getirilmiştir.

3.7.1. Veri setinin karmaşıklığının yorumlanması

Elde edilen veri seti miktar olarak yüksek boyutlu değildir. Bu nedenle uygun veri artırım teknikleri literatür taraması esnasında değerlendirilmiştir. Dizüstü bilgisayar devrelerinin karmaşık yapısı ayrıca eldeki patlayıcı devrelerinin kısıtlılığı sebebiyle, bu yöntemlerden GAN tabanlı yöntemler vasıtasıyla gerçekleştirilen sentetik veri artırım yöntemlerinin uygulanma imkânının düşük olduğu tespit edilmiştir. Sebep olarak yapılan literatür taramasında, kullanılan artırım yöntemlerinde daha uniform yapıdaki basit bıçak vb. gibi nesnelerin üretildiği görülmüştür. Bunun dışında kes çıkar (cutout), karıştırma (mixup) gibi kesme vb. mantıktaki artırım yöntemleri kesilen yerdeki görüntünün tehlikeli madde içerip içermediğine bağlı olarak etiket değerlerini değiştireceği için veri artırımı sürecinde kullanılmamıştır.

Sınıflar Arası Varyasyon (Interclass Variation): Bu kavram, farklı sınıflar arasındaki değişkenliği ifade eder. Yani, sınıflar arasında ne kadar farklılık olduğunu ölçer. Yüksek bir sınıflar arası varyasyon, sınıflar arasındaki ayrımın belirgin olduğunu

gösterir; bu da sınıfların birbirinden ne kadar uzak olduğunu anlamamıza yardımcı olur. Genellikle, sınıflar arası varyasyon, sınıfların ortalamaları arasındaki mesafenin karelerinin toplamı ile hesaplanır.

Sınıf İçi Varyasyon (Intraclass Variation): Bu kavram, aynı sınıf içindeki örneklerin birbirine ne kadar benzer olduğunu ifade eder. Yani, sınıf içindeki bireyler arasındaki değişkenliği ölçer. Düşük bir sınıf içi varyasyon, sınıf içindeki bireylerin birbirine çok benzer olduğunu, yüksek bir varyasyon ise bireyler arasında büyük farklılıklar olduğunu gösterir. Sınıf içi varyasyon, genellikle sınıf içindeki bireylerin ortalamalarına olan uzaklıkların karelerinin toplamı ile hesaplanır.

Kısaca, sınıflar arası varyasyon sınıflar arasındaki farklılıkları, sınıf içi varyasyon ise sınıf içindeki benzerlikleri ölçer.

Oluşturulan bu veri setinin karmaşıklık açısından değerlendirmesi yapılmak istendiğinde ise su sonuçlara varılmıştır. Oluşturulan görüntüler için teknoloji olarak X-ray cihazları kullanıldığı için bu cihazlardan üretilen görüntüler nesnelerden yansıyan veya soğurulan x-ışınlarının toplamı olmaktadır. Bu da özellikle sınıf içi varyasyonun yüksek olmasına neden olmaktadır. Yani bir nesnenin görüntüsündeki üst üste binme, açı değişikliği gibi faktörler nedeniyle nesnenin özelliklerinin çok fazla değişmesi, bu özelliklerin öğrenilmesini zorlaştırmaktadır. Bu durum, kullanılan yöntemler açısından nesnenin ayırt edici özelliklerinin belirlenmesini güçleştirmektedir. Bunun dışında sınıflar arası varyasyon durumunu incelediğimizde ise kullanılan devrelerle patlayıcı devrelerinin çeşitli komponent ve materyal olarak benzerlik göstermesinden ötürü ayırt edici özelliklerinin yüksek olması beklenmemektedir. Bu özellikte sınıflar arası varyasyonu düşürmekte dolayısıyla ayırt ediciliği azaltmaktadır. Bunun gibi sebeplerden ötürü ilgili hazırlanan veri setinin karmaşıklığının yüksek olduğunu düşünmekteyiz. Bu da yaptığımız deneyler ve deney sonuçları yorumlanırken göz önünde bulundurulacaktır.

Yukarıda bahsedilenlere ek olarak X-ray görüntüleri doğal görüntüler/resimler gibi zengin özellikler barındırmamaktadır. Örneğin kısıtlı renk aralığına, daha düşük kontrasta ve zayıf bir desen/dokuya (texture) sahiptirler. Ayrıca önceki bölümlerde anlatılan X-ray görüntülerinin açığa, uzaklığa, üst üste binmeye vb. durumlarına göre farklılık arz etmesi nedeniyle özellikle çok fazla aykırı değer veya gürültü içermektedirler. Bu üst üste binme durumu derin öğrenme modellerini kullanırken sınıf içi varyasyonu artırmasından ötürü ayrıca bir zorluk olmaktadır (Dumagpi ve Jeong, 2021b).

3.8. Önerilen Yöntemler

3.8.1. Derin öğrenme ile özellik çıkarımı

Özellik çıkarımı, orijinal veri setindeki bilgiyi koruyarak ham verilerin işlenebilir sayısal özelliklere dönüştürülmesi sürecini ifade eder. Bu ise makine öğrenimini doğrudan ham verilere uygulamaktan daha iyi sonuçlar verir. Otomatik ve el ile olmak üzere iki türü vardır. Bunlardan otomatik özellik çıkarımında özel algoritmalar, derin ağlar resim veya sinyallerden insan müdahalesine gerek olmadan özelliklerin çıkarılması işlemini gerçekleştirirler. Bu yöntemlere örnek olarak Dalgacık Saçılması (Wavelet Scattering) verilebilir (MathWorks, 26.10.2024).

Derin öğrenme mimarilerinin klasik yapay sinir ağlarından temel farkı ham verilerden özellik çıkarabilmesidir. Özellikle görüntü işleme, analiz ve sınıflandırmada popüler olmasının önemli bir nedeni her pikselin bir özellik olarak alındığı durumda, görüntü çözünürlüğüne bağlı olarak milyonlarca özellik ortaya çıkabilmesidir. Görüntü analizi veya sınıflandırmada kullanılan evrişimsel filtrelerinin temel amacı özellik haritasının çıkarılmasıdır. Genellikle çıkarılan özellik sayısı uygulanan filtre sayısına bağlı olarak yüksek olduğundan dolayı filtre katmanlarını takip eden bir havuzlama katmanı bulunmaktadır. Şekil 3.3.'te filtrelemenin genel şeması ve Şekil 3.4.'te bir havuzlama gösterilmiştir.

Farklı sayıda evrişimsel filtre ve havuzlama kullanılması, kaybolan gradyanın engellenmesi amacıyla katmanlar arası bağlantı yapısının iyileştirilmesi, ölçeklenebilirlik, hesaplama maliyetini azaltmak, daha yüksek performanslı modeller elde etmek amacıyla farklı mimariler literatürde önerilmiştir. Bu çalışma kapsamında ise ResNet, DarkNet, EfficientNet, DenseNet, MobileNet, Inceptionv3, ShuffleNet ve Xception modelleri veri kümesi ile eğitilmiş ve özellik haritaları bu mimarilerden elde edilmiştir. Bilindiği üzere derin öğrenme yöntemlerinin klasik makine öğrenmesi yöntemlerinden en önemli farkı ham veriden özellik çıkarabilmesi ve bu özelliklerle yapay sinir ağlarının eğitilebilmesidir. Özellikler elde edildikten sonra kNN (Sani ve diğ., 2017; Singh ve diğ., 2020; Benyahia ve diğ., 2022), SVM (Singh ve diğ., 2020; Benyahia ve diğ., 2022), Naive-Bayes (Singh ve diğ., 2020; Benyahia ve diğ., 2022) gibi farklı makine öğrenmesi yöntemlerinin uygulandığı veya farklı yöntemler kullanılarak özellik seçiminin yapıldığı çalışmalar literatürde bulunmaktadır. Tez kapsamında 11 derin öğrenme yönteminden özellik vektörleri elde edilmiştir. Bu işlem eğitim süreci

tamamlandıktan sonra ve tam bağlantılı katmandan hemen önce özellik haritalarının elde edilmesi şeklinde gerçekleştirilmiştir. Şekil 3.20’de örnek olarak verilen yapı ResNet18 derin öğrenme mimarisinin eğitiminden sonra elde edilmiştir.



Şekil 3.20. ResNet mimarisinden özellik çıkarılan katman

Şekil 3’teki modelin verilerle eğitimi yapıldıktan sonra eğitilmiş ağı verilir ve evrişim, havuzlama vb. katmanlardan geçirilen veri tam bağlantılı katmandan hemen önce bu özellikler olarak elde edilir. Çizelge 3.9’de modeller, özellik çıkarılan katmanlar verilmiştir.

Çizelge 3.9. Derin öğrenme modellerinden özellik çıkarılan katmanlar


Modeller	Özellik Çıkarılan Katman
EfficientNet	globavgpool
ResNet18	pool5
ResNet50	avgpool
ResNet101	pool5
DarkNet19	conv19
DarkNet53	conv53
MobileNetV2	global_average_pooling
ShuffleNet	node_200
InceptionV3	avg_pool
DenseNet201	avg_pool
Xception	avg_pool

Çizelge 3.9, özellik çıkarma için seçilen katmanlara ve çıkarılan özelliklerin boyutluluğuna göre farklı derin öğrenme modellerini karşılaştırılmasına yardımcı olur. Özellik sayısı, her bir modelin girdi verilerinden bilgi yakalamadaki karmaşıklığını ve ifade gücünü göstermektedir.

3.8.2. Sonradan özellik füzyonu

Nesnelerin tespitinde farklı özellikler genellikle görsel karakterlilerin farklı yönlerini tanımlarlar. Nesne görünümündeki çeşitlilik dolayısıyla heterojen görsel özelliklerin birleştirilmesi, yüksek performanslı nesne tespiti için bir şekilde gereklidir. Özellik birleştirme, daha kapsamlı bir özellik temsili oluşturmak amacıyla birden fazla görsel ipucu bilgisinin entegrasyonunu teşvik eder. Tamamlayıcı özelliklerin birleştirilmesi, nesne tespitinde önemli bir iyileşmeye yol açabilir (Cheng ve Han, 2016). Sık kullanılan bir birleştirme yöntemi ise sonradan özellik füzyonu (late feature fusion) isimli yöntemdir. Bu yöntemde farklı özellikler veya sınıflandırıcılar eğitim sonrası birleştirilirler. Aşağıda bu tezde de kullanılan ilgili birleştirme işleminin nasıl gerçekleştirildiği verilmiştir.

Tez kapsamında yapılan çalışmada N özellik bir derin öğrenme yönteminden ve M adet özellik farklı bir derin öğrenme yönteminden çıkarıldıktan sonra n ($n \leq N$) ve m ($m \leq M$) adet özellikten oluşan iki adet veri kümesi elde edilir. Elde edilen bu veri kümeleri $(n \mid m)$ ve $(m \mid n)$ şeklinde birleştirilerek tekrar eğitim ve sınıflandırma yapılmaktadır. Özellik çıkarma, birleştirme, RWN ile eğitim ve test süreçlerinin genel diyagramı Şekil 3.21’de verilmiştir.



Şekil 3.21. Deneylerde kullanılan sınıflandırma ve görüntü işleme sürecinin diyagramı

Şekil 3.21’de özellikler kümesi çıkarıldıktan sonra tekrar eğitim ve test süreci için RWN kullanılmaktadır. RWN ile bir yapay sinir ağının eğitiminde yapay sinir ağının yapısal olarak giriş, gizli katman ve çıkış katmanı olmak üzere 3 katmanlı bir yapıda olması gerekir (Huang ve diğ., 2004; 2006). Ayrıca RWN ile yapay sinir ağının eğitimi için iteratif bir süreç bulunmamaktadır ve eğitim süreci geleneksel hatanın geri yayılım algoritmasına göre oldukça hızlıdır. RWN yapay sinir ağının gizli katmanı ile çıkış katmanı arasındaki ağırlıkların analitik bir yöntem ile tek adımda hesaplar. Eğitim süreci tek adımda hesaplandığından dolayı aşırı hızlı bir eğitim sürecine sahiptir. Bunlar da ilgili süreç için RWN’nin seçilme nedenleridir.

Tez kapsamında bu 11 derin öğrenme modelinin her birinin eğitimi sonrası elde edilen özellik haritaları diğer modellerle yukarıdaki şekilde belirtildiği gibi birleştirilir ve sonrasında RWN sınıflandırıcı ile yeniden eğitilerek sınıflandırmaya tabi tutulur. Bu süreç ile diğer topluluk yöntemlerinde olduğu gibi farklı yapılardaki derin öğrenme modellerinin toplam başarılarını artıracakları düşünülmektedir.

3.9. Performans Değerlendirme Ölçütleri

Derin öğrenme modellerinin performansını değerlendirmede kullandığımız metrikler aşağıdaki verilmiştir.:

Karmaşıklık Matrisi: Gerçek pozitif, gerçek negatif, yanlış pozitif ve yanlış negatifleri görselleştirmek için yararlı bir araçtır. Çizelge 3.10’da ilgili matrisin doğruluk durumlarının gerçek ve tahminlere göre dağılımı gösterilmektedir.

Çizelge 3.10. Karmaşıklık matrisi

		Tahmin	
Gerçek		Pozitif	Negatif
	Pozitif	Doğru Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Doğru Negatif (TN)

Doğruluk (Accuracy): Toplam örnek sayısına göre doğru sınıflandırılan örneklerin yüzdesi olarak tanımlanabilir. İlgili formül Eşitlik 3.20’de verilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3.20)$$

Hassasiyet (Precision)(P): Pozitif tahminlerin kalitesine odaklanır. Modelin pozitif olarak sınıflandırdığı örneklerin doğruluğunu ölçer. Gerçek pozitif (TP) kayıtların sayısının, gerçek pozitif (TP) ve yanlış pozitif (FP) olarak sınıflandırılan kayıtların toplamına oranı olarak tanımlanır. İlgili formül Eşitlik 3.21’de verilmiştir.

$$Hassasiyet = \frac{TP}{TP+FP} \times 100\% \quad (3.21)$$

Duyarlılık (Recall)(R): Duyarlılık modelin pozitif örnekleri tespit yeteneğini ölçer. Gerçek pozitif kayıtların sayısının, gerçek pozitif (TP) ve yanlış negatif (FN) olarak sınıflandırılan kayıtların toplamına oranı olarak tanımlanır. İngilizce Sensitivity olarak da geçer. İlgili formül Eşitlik 3.22’de verilmiştir.

$$Duyarlılık = \frac{TP}{TP+FN} \times 100\% \quad (3.22)$$

F-Ölçütü (F-Measure) (F): Hassasiyet ve duyarlılığın harmonik ortalaması olarak tanımlanır ve ikisi arasındaki dengeyi temsil eder. İlgili formül Eşitlik 3.23’te verilmiştir.

$$F - \text{Ölçütü} = \frac{2PR}{P+R} \quad (3.23)$$

Özgüllük (Specificity):

Derin öğrenmede (özgüllük), genellikle bir modelin negatif örnekleri doğru bir şekilde tanımlama yeteneğini ifade eder. Gerçek negatiflerin (gerçekte olumsuz olan) model tarafından doğru bir şekilde sınıflandırılma oranını ölçer. İlgili formül Eşitlik 3.24’te verilmiştir.

$$Hassasiyet = \frac{TN}{TN+FP} \times 100\% \quad (3.24)$$

G-ortalama: duyarlılık ve özgüllüğün geometrik ortalaması olarak tanımlanır ve şu formülle hesaplanır: İlgili formül Eşitlik 3.25’te verilmiştir.

$$G\text{-ortalama} = \sqrt{\text{duyarlılık} \times \text{özgüllük}} \quad (3.25)$$

Bu formül, modelin pozitif ve negatif sınıfları doğru bir şekilde ayırt etme yeteneğini birleştirir. Tüm sınıfların doğruluk değerlerini yüksek tutmaya çalışırken bu değerlerin aralarındaki dengeyi korumaya çalışır.

G-ortalama, özellikle dengesiz veri setlerinde, yanlış pozitif oranlarını (duyarlılık) ve yanlış negatif oranlarını (özgüllük) dikkate alarak her bir sınıfın değerlendirme sürecinde yeterince temsil edilmesini sağlayarak daha bütüncül bir değerlendirme yapılmasını sağlar.

ROC-AUC: İkili sınıflandırma için, farklı eşiklerdeki performansı değerlendirmek amacıyla Alıcı İşlem Karakteristik (ROC) eğrisi ve Eğri Altındaki Alan (AUC) kullanılabilir.



4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde ise problemleri çözmek için geliştirilen yöntemler karşılaştırılmış, test setinin çözümündeki performansları ve etkinlikleri dikkate alınarak dikkatlice incelenmiş ve yorumlanmıştır.

Bu bölümdeki deneyler iki aşamada gerçekleşmiştir. Birincisi olan sınıflandırma problemi deneyleri; eğitim, doğrulama ve test olarak ayrıştırılarak performansı bu alanda iyi bilinen 11 algoritma ile yapılan deneylerle ve karşılaştırmalarla gösterilmiştir. İkinci aşamada ilgili sınıflandırmaların performansı ve karşılaştığı aşırı öğrenme vb. sorunları çözmek için RWN sınıflandırıcı kullanan bir özellik birleştirme yöntemi önerilmiştir. Bu yöntem ise içerdiği aktivasyon fonksiyonu ve gizli katman sayısı parametrelerinin çeşit ve boyutuna göre performans karşılaştırmalarına tabi tutulmuştur. İlgili deneyler AMD Ryzen 9 5950X CPU@3.401GHz işlemciye sahip ve 64GB RAM Nvidia Geforce rtx 3080 12 GB ekran kartı bulunan bir bilgisayarda gerçekleştirilmiştir.


4.1. Derin Öğrenme Yöntemleri ile Özellik Haritalarının Elde Edilmesi

Daha önce bahsedilen X-ray tabanlı yöntemlerden olan çanta veya bagaj vb. eşyaların içinde bulunan yasaklı maddelerin tespiti konularından farklı olarak doğrudan dizüstü bilgisayarlar içerisinde gizlenmiş bilgisayar içerisinde bulunma ihtimali olmayan devrelerin tespiti gerçekleştirilmiştir. Bu amaçla önce veri seti oluşturularak görüntü içerisindeki gereksiz kısımlar veri ön işleme ile çıkarılmıştır. Ayrıca elde edilen son görüntülerden oluşan veri setinin herhangi bir sınıfa karşı eğilimli (bias) olmaması için patlayıcı içeren bazı görüntüler çıkarıldıktan sonra eşit şekilde bölünerek yeniden düzenlenmiştir.

Çalışmanın ilk aşamasında oluşturulan bu yeni veri seti ile literatürde mevcut yöntemlerin eğitilerek problemin çözüm başarısı sınanmıştır. Bunun için ilk aşamada literatürdeki genel geçer yöntemler araştırılmış ve bunların gereklilikleri ortaya konulmuştur (giriş boyutu, katman sayısı vb.). Bunlar arasından 11 adedi son aşamada kullanılmıştır. İlk aşamada elde edilecek bu modeller ikinci aşamadaki deneyler için girdi olarak kullanılmıştır.

4.1.1. Derin öğrenme algoritmalarının eğitilmesi ve test edilmesi

Tezde kullanılan derin öğrenme yöntemlerinin performansı oluşturulan veri seti üzerinde 10-katlı çapraz doğrulama ile araştırılmıştır. Öncelikle veri seti 10 parçaya bölünmüş ve 9 parçası eğitim-doğrulama amacıyla son parçası ise test için kullanılmıştır. Her katın eğitim için bölünen parçasının %70'i eğitim ve %30'u doğrulama için kullanılmıştır. Bölümlerdeki görüntü sayılarına ilişkin dağılım Şekil 4.1'de gösterilmiştir.



Şekil 4.1. 10-katlı çapraz doğrulamada kullanılan görüntülerin eğitimdeki dağılımı


Çizelge 4.1'de ise ilgili sınıflandırma modellerinin eğitimi sırasında kullanılan varsayılan hiperparametre değerleri verilmiştir. Hiperparametre değerleri sınıflandırma için sabit tutulmuştur.

Çizelge 4.1. Derin öğrenme modellerinin hiperparametre değerleri

Hiperparametre	Değer
Başlangıç öğrenme oranı	0.001
Maks epok Sayısı	3000
Epoktaki tekrar adedi	100
Öğrenme oranı periyodu	Sabit
Bir devirde kullanılacak görüntü sayısı (Mini Batch Size)	32
Optimizasyon algoritması	Adam


Verinin bölümlenmesi ve her bölümdeki görüntüler ve sıralaması 11 derin öğrenme içinde aynı olacak şekilde ayarlanmıştır. Şekil 4.1'de normal, içinde devre

gizlenmemiş dizüstü bilgisayar X-ray görüntüsünü, anormal içinde devre gizlenmiş dizüstü bilgisayar görüntüsünü ifade etmektedir ve görüntülerin etiketi olarak kullanılmıştır. Hiper parametre değerleri Çizelge 4.1’de verilen 11 derin öğrenme modeli eğitim seti üzerinde eğitilmiş ve 10 katlı çapraz doğrulamaya ait tek bir katın eğitimi sırasındaki doğruluk ve kayıp değerlerini veren sonuçlar öncelikle en başarılı yöntem olan ShuffleNet için Şekil 4.2’de verilmiştir.



Şekil 4.2. Tek bir kat (fold) için ShuffleNet eğitim performansları

Şekil 4.3’te ise tüm modellere ait eğitim kümesi üzerinde 10 katmanlı doğrulama performansları ortalaması topluca verilmiştir.




Şekil 4.3. Derin öğrenme mimarilerinin toplu eğitim performansları

Şekil 4.3'te sunulan eğitim performansları, eğitim sürecinde farklı modeller için aynı çevrimlerden elde edilen değerlerdir. Tüm modeller, başlangıçta yaklaşık olarak 55% civarında düşük bir doğrulukla eğitime başlayıp eğitim süreci boyunca giderek performansları artmıştır. Doğruluk değerleri sürekli bir artış eğilimi gösterdiğinden dolayı tekrarların yeterli olduğu değerlendirilmektedir. Tüm modeller için doğruluk değerlerinin genellikle yüksek olması, modellerin sınıflandırma görevini iyi bir şekilde öğrenebildiği anlamına gelmektedir. DarkNet53 dışındaki modellerin eğitim başarıları %85'in üzerinde olduğu görülmektedir. EfficientNet ve ShuffleNet modelleri, eğitim aşamasında en yüksek doğruluk değeri elde etmişlerdir, bu da bu mimarilerin X-ray görüntülerinden sınıflandırılması görevi için özellikle uygun olabileceğini göstermektedir. Diğer yandan, Inception, DenseNet, DarkNet19, DarkNet53, MobileNet, ResNet18, ResNet50, ResNet101 ve Xception modelleri için eğitim başarıları EfficientNet ve ShuffleNet'ten daha düşüktür. Derin öğrenme modelinin öğrenme hızı, modelin eğitim süreci sırasında doğruluğunu ne kadar hızlı bir şekilde artırabildiğini ifade eder. Öğrenme hızı, modelin karmaşıklığı, eğitim veri kümesinin büyüklüğü, kullanılan optimizasyon yöntemi ve hiper parametreleri, kayıp fonksiyonunun seçimi ve düzenleme tekniklerinin varlığı gibi çeşitli faktörlerden etkilenebilir. Verilere göre, ShuffleNet modelinin en yüksek doğruluğa sahip olduğu görünmektedir ve diğer modellere göre daha hızlı bir şekilde en yüksek doğruluğa ulaşmaktadır. ShuffleNet toplam epokların yaklaşık %30'unda %98 doğruluğa ulaşırken, EfficientNet %98 doğruluğa ulaşmak için yaklaşık olarak toplam epokların %36'sını kullanmaktadır. MobileNet ve Xception yaklaşık olarak %65 epok alırken, DenseNet,

DarkNet19, DarkNet53, ResNet18, ResNet50, ResNet101 ve Inception yaklaşık olarak %90-95 epokta eğitime devam etmektedir.

Genel olarak, doğruluk sayısı, epok sayısı arttıkça artıyorsa, bu, modelin eğitim verisinden öğrenme göstergesi olarak kabul edilir. Ancak, eğitim doğruluğu yalnızca modelin performansının bir yönüdür. Bununla birlikte, eğitim verisinde yüksek doğruluk, modelin yeni veriler üzerinde iyi performans göstereceği anlamına gelmez. Ezberlemeyi kontrol etmek için, modelin doğruluğunu eğitim verisi dışında ayrılan ve modelin performansını değerlendirmek için kullanılan bir doğrulama veri kümesi üzerinde de araştırmak gerekir. Doğrulama, derin öğrenme modelinin bir doğrulama veri kümesinde ne kadar iyi performans gösterdiğini ölçer. Bu doğrulama veri kümesi, modelin hiper parametrelerini ayarlamak ve performansını değerlendirmek için kullanılan eğitim verisinin bir alt kümesidir. Yüksek bir doğrulama performansı, modelin doğrulama örneklerinin yüksek bir yüzdesini doğru bir şekilde sınıflandırabildiğini gösterirken, düşük doğrulama performansı, modelin eğitim verisini ezberlediğini veya eğitim verisini öğrenmediğini göstermektedir. Modellerin doğrulama veri seti üzerindeki ortalama performansı toplu olarak Şekil 4.4'te verilmiştir.



Şekil 4.4. Derin öğrenme mimarilerinin toplu doğrulama performansları

Şekil 4.4'te verilen doğruluk performanslarına göre, ShuffleNet modeli %85'lik en yüksek doğrulama performansına sahiptir. Ayrıca, verilen değerler aralığı boyunca sürekli yüksek doğruluk elde etmektedir. Bu, ShuffleNet modelinin doğrulama veri kümesinde iyi bir performans sergilediğini ve genelleme yapabildiğini göstermektedir. Inception modeli %84 ile ikinci en yüksek doğrulama performansına sahipken,

DarkNet19 %81 ve DenseNet %79 doğruluk değerine sahiptir. EfficientNet, ResNet50, DarkNet53, MobileNet, ResNet18, ResNet101 ve Xception modelleri ise en yüksek %60-75 arasında doğrulama performansına sahiptir. Sınıflandırma görevinde önemli bir diğer kriter mimarilerinin test verisi üzerindeki performanslarıdır. Çizelge 4.2 ve Çizelge 4.3'te sırasıyla raporlanan eğitim ve test sonuçları, her çapraz doğrulama katından elde edilen modellerin ortalamasıdır.

Çizelge 4.2. Derin öğrenme mimarilerinin eğitim kümesinin tamamında 10-katlı çapraz doğrulama eğitim sonuçları

Model	Doğruluk	Duyarlılık	Özgüllük	Hassasiyet	F-Ölçütü	G-Ortalama
EfficientNet	87,42	86,59	88,24	88,07	87,30	87,39
DenseNet	88,56	88,20	88,90	88,83	88,50	88,54
DarkNet19	88,17	86,69	89,66	89,39	88,00	88,14
DarkNet53	69,46	73,03	65,88	69,90	70,32	67,92
Inception	92,02	89,83	94,21	93,96	91,81	91,98
MobileNet	87,47	87,54	87,41	87,48	87,47	87,44
ResNet18	88,45	87,69	89,21	89,11	88,34	88,41
ResNet50	87,14	86,22	88,06	87,97	87,00	87,08
ResNet101	86,66	86,96	86,34	86,52	86,67	86,60
ShuffleNet	94,39	93,97	94,81	94,80	94,37	94,38
Xception	90,91	91,00	90,81	90,88	90,91	90,88


Çizelge 4.3. Derin öğrenme mimarilerinin test kümesinde 10-katlı çapraz doğrulama test sonuçları

Model	Doğruluk	Duyarlılık	Özgüllük	Hassasiyet	F-Ölçütü	G- Ortalama
EfficientNet	59.13	57.45	60.90	59.43	58.23	58.95
DenseNet	77.72	76.58	78.84	78.43	77.41	77.64
DarkNet19	78.94	76.98	80.78	80.27	78.48	78.77
DarkNet53	66.98	70.77	63.26	67.15	67.84	65.47
Inception	81.31	77.96	84.47	83.69	80.62	81.07
MobileNet	60.23	59.53	60.82	60.51	59.78	59.86
ResNet18	65.88	62.67	69.00	67.03	64.62	65.61
ResNet50	62.58	59.53	65.50	63.60	61.26	62.16
ResNet101	61.01	61.79	60.51	61.08	61.06	60.77
ShuffleNet	83.55	81.99	85.30	84.90	83.22	83.52
Xception	71.26	70.84	71.82	71.73	70.98	71.08

ShuffleNet, tüm mimariler arasında en iyi test performansına sahiptir. Hesaplama maliyetini azaltmak için kanal karıştırmanın etkisi eğitim ve test veri kümeleri sonuçları üzerinde görülmektedir. Inception, DarkNet19 ve DenseNet ise test performans açısından yakındır. Inception mimarisi, performansı artırmak ve ezberlemeyi azaltmak için evrişim,

havuzlama ve yardımcı sınıflandırıcıların bir kombinasyonunu kullanır. DarkNet19, ResNet'in basitleştirilmiş bir versiyonudur. Hızlı ve kullanımı kolay olacak şekilde tasarlanmıştır. Her iki mimari de performansı ve verimliliği artırmak için tasarlanmıştır. Xception, ResNet18, ResNet50 ve ResNet101 diğer modellere göre nispeten daha düşük performansa sahiptir. Daha düşük performansın nedeni muhtemelen temsil kabiliyetlerinin azlığı, mimarilerinin getirmiş olduğu optimizasyon zorluğu problemlerinin altından kalkamamaları olabilir. ResNet18 ve ResNet50, diğer modellere göre daha sığ bir derinliğe sahiptir ve ResNet101 en fazla derinliğe sahiptir, bu da eğitim ve test başarılarındaki farklardan da görüleceği üzere ezberlemeye ve daha düşük performansa yol açmaktadır. EfficientNet ve MobileNet benzer performans gösterir ve modeller arasında en düşük performansa sahiptir. Düşük performanslarının nedeni doğruluk ile hesaplama karmaşıklığı arasındaki dengeyi kuramamalarıdır. Her iki mimari de verimli olacak şekilde tasarlanmıştır, ancak bu bazı doğruluk kayıplarıyla gelir. DarkNet53, EfficientNet ve MobileNet'ten daha iyi bir performansa sahiptir, ancak diğer modellere göre hala daha düşük bir performansa sahip olduğu sonuçlardan görülmüştür. Düşük performans gösteren bu modeller genelde kardinalite gibi yapılar açısından daha basit modellerdir. Bu da onların temsil kabiliyetlerine etki etmektedir. Ayrıca veri setinin tanıtıldığı kısımda bahsedildiği gibi veri seti; oldukça zor, karmaşık ve gürültülüdür. Bu da ilgili yöntemlerin bunlara bağlı olarak düşük performans göstermelerine sebep olmuştur.

Son olarak ise ilgili 10 katlı çapraz doğrulamanın her bir aşaması (kat) yani tek bir modelin eğitim süresi ve boyutu için gereken değerleri gösteren grafik Şekil 4.5'te verilmiştir.



Şekil 4.5. CNN modelleri eğitim süreleri ve disk kullanımları

4.2.1 Sınıflandırma sonuçların değerlendirilmesi

Elde edilen veri öğrenme seti üzerinde yapılan patlayıcı tespitin ilk sonuçlarının yorumlanması burada yapılmış ve tez çalışmasının sonraki aşamasında kullanılan yöntem bu sonuçlara göre önerilmiştir. Bu sebeple ilgili deneylerle alakalı sonuçlara ait değerlendirme burada yapılmıştır.

Derin öğrenme yöntemlerinin başarıları karşılaştırılırken aradaki farkları belirleyen çok fazla etmen vardır (parametre sayısı, hiper parametre seçimi, katman sayısı vb.). Literatürde görüleceği üzere kara kutu gibi davranan bu yöntemlerin neden daha başarılı olduklarını açıklamak oldukça zor olmaktadır. Bu sebeple kesin olmamakla beraber başarılar arası ana faktörlerden bahsedilecektir. Genelde daha az başarılı olan yöntemler temsil kapasitesi diğerlerine göre daha az olan yöntemler olmuştur. Bunun üstesinden ise grup evrimi (konvolüsyonu) ile filtreler arasındaki bilgiyi daha iyi ileten ve bu sebeple gürültüye karşı daha dayanıklı olan ShuffleNet ve ayrıca Inceptionv3, DenseNet gibi dallanan bloklar halinde ilerleyerek kardinalite ve genişliği artırarak temsil kabiliyetini güçlendiren yöntemler daha başarılı şekilde gelmiştir. Bunun dışında bu yapıların başarı farklarında içerdikleri düzenleme tekniklerinin (yardımcı sınıflandırıcılar vb.) de etkisi bulunmaktadır. Ayrıca derinlik özelliklerinin artırılması sonrası bu kapasite artışının optimizasyonunun getirdiği zorluklar nedeniyle yöntemler ezber yapmaya başlamışlardır. Bunu engellemek için yapılabilecek en faydalı çözüm veri seti boyutunun artırılması içerisindeki sınıflandırılmayı zorlaştıran varyasyonun bu sayede azaltılması

olmalıdır. Ancak maddiyat ve zaman kısıtları gibi nedenlerden ötürü bunu yapmak mümkün olmadığından alternatif yöntemlere bakmakta fayda görülmüştür. Son olarak yöntemlerde artırılan derinliğin kazanım olarak çok fazla bir getirisini olmadığı özellikle ResNet gibi modellerde görülmüştür.

Veri seti boyunu artırmak için alternatif olarak sentetik yöntemlerin kullanılması akla ilk olarak gelmektedir. Yapılan literatür taramasında X-ray görüntüsü ile yapılan diğer çalışmalarda daha çok basit (uniform) yapıdaki silah, bıçak vb. görüntülerin GAN tabanlı yöntemler ile çoğaltılarak artırıldığı görülmüştür. X-ray görüntüleri doku vb. bilgiler içermediği için bu tarz kullanımda başarılı olsa da oluşturulan veri setinde kullanılan dizüstü bilgisayarların ve patlayıcı devrelerinin kısıtlı sayıda ve karmaşık olması nedeniyle zorluk açısından bu yöntemlerin kullanılması mümkün gözükmemiştir.

Bu nedenle en iyi alternatif olarak ilgili derin öğrenme modellerinin topluluk (ensemble) tarzı bir yapıda kullanılarak değerlendirildiği ve başarılarının bu sayede artırıldığı yöntemler araştırılmıştır. Ayrıca mevcut olan ezberleme problemine de karşı direnç artırmak bu yöntemin temel gereksinimlerinden biri olarak görülmüştür. Daha derin ağlar inşa etmek bu sorunu artıracığı için tüm etkenler değerlendirildikten sonra özellik birleştirme ile temsil kabiliyeti daha yüksek haritalar elde ederek başarımın artırılabilceği öngörüsünde bulunulmuştur. Bu birleştirilen özelliklerin sınıflandırılmasında ise, global ortalama gibi yöntemler farklı modellerden özellikleri birleştirildiği için etkisiz olacağı öngörülmüştür. Tam bağlı bir ağın ise ezberleme meyli yüksektir. Bunun dışında en mantıklı seçenek ise diğer sınıflandırıcılardan farklı olarak özellikle eğitim süresinin tek adımda olması ve ezbere karşı direnci nedeniyle RWN olarak görülmüştür.

4.3. Birleştirme Deneyleri ve Performans Analizi

Özellik çıkarılmak için derin öğrenme yöntemlerinin mevcut veri seti üzerinde eğitilmesi işleminin tamamlanmasından sonra birleşim işlemine geçilmiştir. Sınıflandırma çalışmasında görüldüğü üzere, en yüksek sınıflama doğruluğuna ShuffleNet ile ulaşılmıştır ve %83,55 doğruluk elde edilmiştir. İkinci en yüksek doğruluk ise %81,31 ile Inception mimarisi ile elde edilmiştir. Bu çalışmada bu mimarilerden çıkarılan özellikle ile daha yüksek doğrulukta bir sınıflandırma yapılması hedeflenmiştir. Sınıflandırma çalışmasındaki yöntemlerden çıkarılan özellik sayıları Çizelge 4.4'te sunulmuştur.

Çizelge 4.4. Derin öğrenme mimarilerinden çıkarılan özellik sayıları

Model	Çıkarılan Özellik Sayısı
EfficientNet	1280
ResNet18	512
ResNet50	2048
ResNet101	2048
DarkNet19	128
DarkNet53	1024
MobileNetV2	1280
ShuffleNet	544
InceptionV3	2048
DenseNet201	1920
Xception	2048

Çizelge 4.4'te verilen özellik sayıları birleştirilerek elde edilen veri kümelerine ait özellik sayıları Çizelge 4.5'te verilmiştir. Çizelge 4.5'te görüldüğü üzere farklı mimarilerden elde edilen özelliklerin yanı sıra her mimarinin özellikleri yine kendisi ile birleştirilerek veri tekrarının sınıflandırma performansına da etkisi araştırılmıştır.

Bu veri kümeleri kullanılarak RWN ile sınıflandırma deneyleri yapılmıştır. Her deneyde 10 katlı çapraz doğrulama kullanılmıştır. RWN'de giriş katmanı ve gizli katman arasındaki ağırlıklar rastgele atandığından dolayı RWN'nin kullanıldığı her eğitim ve sınıflandırmada 10 katlı çapraz doğrulama 30 defa yapılmıştır. RWN'nin iki parametresi bulunmaktadır. İlk parametre gizli katman nöron sayısı ve ikinci parametre ise aktivasyon fonksiyonudur. Öncelikli olarak ilk parametre olan gizli katman nöron sayısı 50, 100, 250, 500, 1000, 2000 ve 4585 alınarak veri kümeleri üzerindeki eğitim ve test başarıları araştırılmıştır. 4585 sayısı özel olarak seçilmiştir. 10 katlı çapraz doğrulamada her kat için eğitim örnek sayısı 4585 olacağından dolayı gizli katman nöron sayısı 4585 seçildiğinde gizli katman çıkış katmanı arasındaki ağırlık matrisi kare matris olarak elde edilmektedir. Böylelikle ağırlıkların güncellenmesi için matrisin de kare matris haline getirilmesine gerek kalmayacaktır. RWN'nin ikinci parametresi ise aktivasyon fonksiyonudur. Deneylerdeki elde etmeyi beklediğimiz sonuç yüksek bir eğitim başarısı ile yüksek bir test başarısı olduğundan dolayı ortalamada en yüksek test başarısını elde edildiği nöron sayısı ile ikinci parametre araştırılmıştır. RWN'de sıklıkla kullanılan aktivasyon fonksiyonları; tanjant sigmoid, sigmoid, sinüs, kesin sınır (hard limit), üçgen temelli (triangular basis), radyal tabanlı (radial basis) transfer fonksiyonlarıdır.

Öncelikle Çizelge 4.4'te verilen özellikler ve RWN ile birleştirme yapılmadan sınıflandırma yapılmış ve derin öğrenme yöntemlerinin sonuçları ile karşılaştırılmıştır. RWN'de aktivasyon fonksiyonu olarak tanjant sigmoid kullanılmıştır ve karşılaştırma sonuçları Çizelge 4.6'da verilmiştir.



Çizelge 4.5. Derin öğrenme mimarilerinden elde özelliklerin birleştirilmesi ve toplam özellik sayıları

Models	EfficientNet	ResNet18	ResNet50	ResNet101	DarkNet19	DarkNet53	MobileNetV2	ShuffleNet	InceptionV3	DenseNet201	Xception
EfficientNet	2560	1792	3328	3328	1408	2304	2560	1824	3328	3200	3328
ResNet18	1792	1024	2560	2560	640	1536	1792	1056	2560	2432	2560
ResNet50	3328	2560	4096	4096	2176	3072	3328	2592	4096	3968	4096
ResNet101	3328	2560	4096	4096	2176	3072	3328	2592	4096	3968	4096
DarkNet19	1408	640	2176	2176	256	1152	1408	672	2176	2048	2176
DarkNet53	2304	1536	3072	3072	1152	2048	2304	1568	3072	2944	3072
MobileNetV2	2560	1792	3328	3328	1408	2304	2560	1824	3328	3200	3328
ShuffleNet	1824	1056	2592	2592	672	1568	1824	1088	2592	2464	2592
InceptionV3	3328	2560	4096	4096	2176	3072	3328	2592	4096	3968	4096
DenseNet201	3200	2432	3968	3968	2048	2944	3200	2464	3968	3840	3968
Xception	3328	2560	4096	4096	2176	3072	3328	2592	4096	3968	4096

Çizelge 4.6. Derin öğrenme yöntemlerinin ve RWN'nin birleştirme olmadan gizli katmanda farklı nöron sayılarıyla karşılaştırılması

Model	Modelin Sonucu		RWN (50)		RWN (100)		RWN (250)		RWN (500)		RWN (1000)		RWN (2000)		RWN (4585)	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,9844	0,5913	0,8656	0,8615	0,8685	0,8602	0,8765	0,8573	0,8898	0,8518	0,9142	0,8411	0,9595	0,8150	1,0000	0,5688
ResNet18	0,9469	0,6588	0,8708	0,8696	0,8760	0,8725	0,8832	0,8743	0,8922	0,8724	0,9105	0,8629	0,9511	0,8244	1,0000	0,5481
ResNet50	0,9500	0,6258	0,8599	0,8562	0,8664	0,8619	0,8738	0,8625	0,8834	0,8585	0,9007	0,8466	0,9378	0,8008	1,0000	0,5487
ResNet101	0,9344	0,61,01	0,8498	0,8482	0,8549	0,8516	0,8611	0,8491	0,8684	0,8456	0,8883	0,8286	0,9331	0,7784	1,0000	0,5253
DarkNet19	0,8969	0,7894	0,8809	0,8779	0,8854	0,8816	0,8934	0,8821	0,9039	0,8803	0,9242	0,8750	0,9663	0,8452	1,0000	0,5740
DarkNet53	0,7094	0,6698	0,7548	0,7509	0,7647	0,7571	0,7801	0,7601	0,7987	0,7572	0,8336	0,7445	0,8973	0,7072	0,9992	0,5654
MobileNetV2	0,9594	0,6023	0,8467	0,8446	0,8487	0,8441	0,8530	0,8407	0,8629	0,8350	0,8838	0,8219	0,9303	0,7784	1,0000	0,5273
ShuffleNet	0,9906	0,8355	0,9432	0,9424	0,9485	0,9465	0,9537	0,9482	0,9597	0,9477	0,9700	0,9467	0,9900	0,9393	1,0000	0,5745
InceptionV3	0,9219	0,8131	0,9290	0,9276	0,9319	0,9283	0,9390	0,9310	0,9474	0,9304	0,9604	0,9256	0,9831	0,9029	1,0000	0,5669
DenseNet201	0,8813	0,7772	0,9090	0,9072	0,9129	0,9094	0,9208	0,9111	0,9315	0,9107	0,9504	0,9067	0,9814	0,8849	1,0000	0,6113
Xception	0,9844	0,7126	0,9152	0,9126	0,9178	0,9126	0,9240	0,9112	0,9335	0,9072	0,9500	0,8996	0,9780	0,8739	1,0000	0,5733

Çizelge 4.6'dan görüldüğü üzere derin öğrenme yöntemleri ile çıkarılan özellikler kullanılarak RWN ile eğitim ve test yapıldığında test başarısının önemli derece arttığı görülmüştür. Derin öğrenme yöntemlerinde en yüksek başarı ShuffleNet ile %83,55 olarak elde edilmişken ShuffleNet ile çıkarılan özellikler ile RWN gizli katmanında 250 nöron kullanıldığında en yüksek test başarısı %94,82 olarak ölçülmüştür. Ayrıca RWN'de nöron sayısı artarken eğitim başarısı da artmakta fakat test başarısı azalmaktadır. Bu durum özellik çıkarılan bazı mimariler için Şekil 4.6'da gösterilmiştir.



Şekil 4.6. RWN gizli katman nöron sayısının eğitim ve test başarısına etkisi

Çizelge 4.6 ve Şekil 4.6 birlikte değerlendirildiğinde gizli katman nöron sayısının artırmak ağırlık eğitim verisini ezberlemesine neden olmaktadır. RWN'de gizli katman nöron sayısı 250 olarak alındığında ortalama test başarısının daha iyi olduğu ve en iyi sınıflandırma performansına bu parametre değeri ile ulaşıldığı görülmektedir. Bunun yanı

sıra gizli katman nöron sayısı 4585 olarak seçildiğinde test performansı dramatik bir şekilde düştüğünden dolayı birleştirilmiş veri kümeleri üzerindeki testlerde 4585 değeri kullanılmamıştır. Ayrıca deneyler orijinal yöntemlerin sınıflandırıcılarına karşı değerlendirildiğinde ise RWN'nin oldukça başarılı olduğu ve ezberleme vb. problemlerin üstesinden geldiği görülmektedir. Bundan sonraki kısımda artık birleştirilmiş veri kümeleri kullanılmıştır. Birleştirilmiş veri kümeleri üzerinde farklı nöron sayıları ile elde edilen ilgili sonuçlar Çizelge 4.7-4.12'de verilmiştir.



Çizelge 4.7. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Gizli katman nöron sayısı= 50)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8659	0,8618	0,9268	0,9249	0,9205	0,9185	0,9200	0,9183	0,9176	0,9152	0,8823	0,8796	0,9250	0,9238	0,9625	0,9609	0,9635	0,9624	0,9433	0,9418	0,9526	0,9513
ResNet18	0,9268	0,9256	0,8703	0,8684	0,9038	0,9009	0,9023	0,9006	0,9089	0,9066	0,8676	0,8645	0,9017	0,8994	0,9520	0,9506	0,9419	0,9404	0,9241	0,9218	0,9405	0,9385
ResNet50	0,9198	0,9187	0,9033	0,9005	0,8578	0,8555	0,8989	0,8958	0,9024	0,8999	0,8554	0,8518	0,9049	0,9028	0,9520	0,9500	0,9409	0,9388	0,9233	0,9210	0,9327	0,9303
ResNet101	0,9196	0,9180	0,9020	0,8997	0,8986	0,8961	0,8484	0,8458	0,8966	0,8948	0,8526	0,8495	0,9014	0,8985	0,9477	0,9459	0,9425	0,9409	0,9249	0,9233	0,9344	0,9332
DarkNet19	0,9171	0,9149	0,9083	0,9063	0,9027	0,8998	0,8960	0,8937	0,8808	0,8782	0,8764	0,8740	0,9046	0,9020	0,9405	0,9390	0,9125	0,9104	0,9027	0,9002	0,9208	0,9183
DarkNet53	0,8829	0,8814	0,8677	0,8642	0,8544	0,8523	0,8525	0,8492	0,8767	0,8741	0,7514	0,7469	0,8592	0,8576	0,9332	0,9313	0,9179	0,9160	0,8922	0,8906	0,9104	0,9084
MobileNet	0,9249	0,9238	0,9019	0,8997	0,9048	0,9023	0,9016	0,8995	0,9046	0,9015	0,8592	0,8574	0,8463	0,8437	0,9549	0,9536	0,9490	0,9476	0,9328	0,9317	0,9411	0,9400
ShuffleNet	0,9620	0,9613	0,9517	0,9499	0,9524	0,9515	0,9480	0,9467	0,9407	0,9388	0,9333	0,9312	0,9546	0,9535	0,9426	0,9410	0,9634	0,9621	0,9566	0,9544	0,9643	0,9629
Inception	0,9634	0,9622	0,9420	0,9397	0,9410	0,9392	0,9424	0,9411	0,9117	0,9094	0,9174	0,9152	0,9493	0,9475	0,9634	0,9622	0,9285	0,9265	0,9536	0,9527	0,9604	0,9592
DenseNet	0,9432	0,9420	0,9242	0,9220	0,9235	0,9212	0,9256	0,9231	0,9026	0,9001	0,8912	0,8886	0,9329	0,9311	0,9574	0,9561	0,9536	0,9520	0,9089	0,9067	0,9516	0,9504
Xception	0,9528	0,9517	0,9403	0,9387	0,9321	0,9306	0,9344	0,9322	0,9215	0,9192	0,9107	0,9091	0,9411	0,9401	0,9641	0,9630	0,9601	0,9589	0,9517	0,9500	0,9150	0,9119

Çizelge 4.8. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Gizli katman nöron sayısı= 100)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8692	0,8596	0,9327	0,9293	0,9260	0,9226	0,9247	0,9217	0,9276	0,9237	0,8907	0,8868	0,9279	0,9256	0,9682	0,9658	0,9657	0,9639	0,9461	0,9428	0,9543	0,9518
ResNet18	0,9329	0,9300	0,8752	0,8717	0,9135	0,9077	0,9114	0,9081	0,9202	0,9165	0,8808	0,8764	0,9086	0,9051	0,9605	0,9578	0,9496	0,9477	0,9317	0,9284	0,9456	0,9423
ResNet50	0,9262	0,9232	0,9134	0,9086	0,8653	0,8609	0,9093	0,9047	0,9154	0,9111	0,8707	0,8641	0,9138	0,9094	0,9605	0,9584	0,9480	0,9449	0,9324	0,9289	0,9383	0,9347
ResNet101	0,9246	0,9213	0,9118	0,9076	0,9094	0,9043	0,8539	0,8490	0,9094	0,9049	0,8667	0,8612	0,9088	0,9050	0,9567	0,9546	0,9489	0,9465	0,9327	0,9296	0,9400	0,9364
DarkNet19	0,9269	0,9227	0,9206	0,9166	0,9155	0,9109	0,9091	0,9039	0,8855	0,8809	0,8839	0,8792	0,9159	0,9108	0,9533	0,9508	0,9250	0,9217	0,9137	0,9091	0,9320	0,9276
DarkNet53	0,8901	0,8866	0,8808	0,8764	0,8707	0,8646	0,8665	0,8616	0,8839	0,8793	0,7617	0,7548	0,8721	0,8670	0,9447	0,9419	0,9286	0,9256	0,9031	0,8992	0,9182	0,9145
MobileNetV2	0,9279	0,9249	0,9087	0,9049	0,9137	0,9095	0,9090	0,9048	0,9160	0,9120	0,8722	0,8676	0,8487	0,8438	0,9619	0,9596	0,9532	0,9512	0,9372	0,9354	0,9445	0,9416
ShuffleNet	0,9683	0,9664	0,9603	0,9579	0,9606	0,9585	0,9565	0,9541	0,9535	0,9505	0,9446	0,9418	0,9623	0,9602	0,9485	0,9460	0,9705	0,9685	0,9629	0,9610	0,9702	0,9680
InceptionV3	0,9658	0,9640	0,9496	0,9462	0,9481	0,9459	0,9493	0,9469	0,9251	0,9205	0,9291	0,9251	0,9531	0,9506	0,9706	0,9681	0,9313	0,9283	0,9570	0,9547	0,9629	0,9605
DenseNet201	0,9462	0,9427	0,9315	0,9277	0,9322	0,9293	0,9324	0,9293	0,9136	0,9087	0,9027	0,8995	0,9373	0,9342	0,9628	0,9604	0,9570	0,9546	0,9126	0,9087	0,9549	0,9525
Xception	0,9543	0,9520	0,9458	0,9430	0,9382	0,9351	0,9401	0,9364	0,9321	0,9280	0,9181	0,9147	0,9446	0,9415	0,9702	0,9680	0,9628	0,9608	0,9550	0,9525	0,9178	0,9113

Çizelge 4.9. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Gizli katman nöron sayısı= 250)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8780	0,8559	0,9396	0,9318	0,9325	0,9248	0,9299	0,9226	0,9378	0,9289	0,8984	0,8901	0,9325	0,9249	0,9736	0,9694	0,9687	0,9639	0,9516	0,9438	0,9567	0,9510
ResNet18	0,9395	0,9319	0,8821	0,8735	0,9235	0,9134	0,9218	0,9111	0,9315	0,9221	0,8931	0,8823	0,9163	0,9069	0,9673	0,9620	0,9570	0,9499	0,9392	0,9317	0,9514	0,9454
ResNet50	0,9324	0,9249	0,9238	0,9127	0,8729	0,8619	0,9194	0,9088	0,9287	0,9189	0,8843	0,8716	0,9220	0,9124	0,9672	0,9625	0,9543	0,9475	0,9406	0,9334	0,9438	0,9365
ResNet101	0,9301	0,9218	0,9214	0,9114	0,9197	0,9085	0,8604	0,8495	0,9240	0,9127	0,8787	0,8680	0,9172	0,9079	0,9640	0,9589	0,9560	0,9500	0,9406	0,9333	0,9463	0,9383
DarkNet19	0,9376	0,9290	0,9317	0,9215	0,9288	0,9188	0,9239	0,9132	0,8931	0,8822	0,8944	0,8819	0,9281	0,9174	0,9641	0,9569	0,9388	0,9296	0,9257	0,9156	0,9426	0,9346
DarkNet53	0,8986	0,8898	0,8928	0,8826	0,8844	0,8724	0,8787	0,8674	0,8942	0,8831	0,7771	0,7579	0,8842	0,8733	0,9537	0,9485	0,9379	0,9316	0,9138	0,9054	0,9251	0,9170
MobileNetV2	0,9322	0,9251	0,9164	0,9073	0,9220	0,9124	0,9174	0,9079	0,9279	0,9170	0,8845	0,8737	0,8533	0,8406	0,9680	0,9638	0,9580	0,9519	0,9432	0,9372	0,9490	0,9418
ShuffleNet	0,9737	0,9694	0,9673	0,9624	0,9671	0,9621	0,9642	0,9588	0,9640	0,9571	0,9537	0,9477	0,9680	0,9634	0,9536	0,9478	0,9767	0,9724	0,9685	0,9641	0,9750	0,9708
InceptionV3	0,9687	0,9647	0,9570	0,9502	0,9544	0,9484	0,9559	0,9495	0,9387	0,9293	0,9381	0,9315	0,9580	0,9517	0,9768	0,9725	0,9385	0,9290	0,9618	0,9559	0,9662	0,9601
DenseNet201	0,9515	0,9442	0,9393	0,9307	0,9407	0,9321	0,9408	0,9331	0,9257	0,9159	0,9139	0,9059	0,9432	0,9370	0,9686	0,9640	0,9618	0,9559	0,9206	0,9097	0,9599	0,9539
Xception	0,9568	0,9494	0,9515	0,9446	0,9439	0,9360	0,9463	0,9387	0,9422	0,9340	0,9253	0,9175	0,9490	0,9411	0,9751	0,9705	0,9660	0,9604	0,9599	0,9539	0,9239	0,9100

Çizelge 4.10. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Gizli katman nöron sayısı= 500)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8923	0,8512	0,9461	0,9319	0,9389	0,9230	0,9362	0,9213	0,9477	0,9292	0,9062	0,8891	0,9385	0,9233	0,9782	0,9709	0,9732	0,9639	0,9598	0,9430	0,9615	0,9481
ResNet18	0,9461	0,9319	0,8910	0,8711	0,9330	0,9126	0,9303	0,9113	0,9422	0,9236	0,9039	0,8823	0,9239	0,9054	0,9726	0,9634	0,9634	0,9503	0,9474	0,9320	0,9576	0,9444
ResNet50	0,9391	0,9225	0,9329	0,9126	0,8817	0,8581	0,9290	0,9081	0,9401	0,9198	0,8950	0,8704	0,9298	0,9113	0,9725	0,9635	0,9605	0,9465	0,9478	0,9323	0,9495	0,9346
ResNet101	0,9363	0,9211	0,9306	0,9122	0,9289	0,9072	0,8681	0,8441	0,9364	0,9143	0,8888	0,8663	0,9249	0,9061	0,9705	0,9609	0,9619	0,9495	0,9487	0,9340	0,9530	0,9365
DarkNet19	0,9479	0,9299	0,9421	0,9246	0,9402	0,9200	0,9362	0,9154	0,9037	0,8812	0,9057	0,8813	0,9386	0,9194	0,9713	0,9592	0,9496	0,9323	0,9367	0,9170	0,9516	0,9350
DarkNet53	0,9062	0,8880	0,9037	0,8832	0,8951	0,8713	0,8884	0,8660	0,9056	0,8824	0,7933	0,7553	0,8945	0,8729	0,9602	0,9505	0,9453	0,9320	0,9226	0,9064	0,9319	0,9155
MobileNetV2	0,9387	0,9239	0,9240	0,9051	0,9298	0,9111	0,9251	0,9063	0,9384	0,9192	0,8949	0,8727	0,8628	0,8354	0,9731	0,9646	0,9635	0,9515	0,9502	0,9367	0,9553	0,9394
ShuffleNet	0,9781	0,9711	0,9727	0,9641	0,9726	0,9641	0,9705	0,9607	0,9714	0,9596	0,9602	0,9500	0,9732	0,9643	0,9595	0,9481	0,9816	0,9743	0,9739	0,9653	0,9795	0,9719
InceptionV3	0,9733	0,9632	0,9636	0,9509	0,9606	0,9469	0,9618	0,9494	0,9495	0,9327	0,9452	0,9331	0,9636	0,9509	0,9816	0,9744	0,9469	0,9299	0,9680	0,9560	0,9707	0,9593
DenseNet201	0,9596	0,9440	0,9472	0,9323	0,9479	0,9319	0,9487	0,9344	0,9367	0,9175	0,9224	0,9063	0,9502	0,9379	0,9740	0,9655	0,9679	0,9562	0,9313	0,9104	0,9658	0,9546
Xception	0,9613	0,9486	0,9576	0,9445	0,9497	0,9346	0,9531	0,9369	0,9521	0,9352	0,9320	0,9148	0,9553	0,9397	0,9794	0,9718	0,9708	0,9591	0,9658	0,9543	0,9331	0,9068

Çizelge 4.11. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Gizli katman nöron sayısı= 1000)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,9183	0,8410	0,9577	0,9278	0,9503	0,9178	0,9477	0,9167	0,9629	0,9287	0,9201	0,8767	0,9519	0,9181	0,9847	0,9706	0,9822	0,9601	0,9739	0,9410	0,9718	0,9433
ResNet18	0,9577	0,9271	0,9081	0,8615	0,9478	0,9051	0,9452	0,9051	0,9589	0,9212	0,9210	0,8746	0,9381	0,8985	0,9803	0,9627	0,9729	0,9485	0,9604	0,9285	0,9684	0,9397
ResNet50	0,9504	0,9164	0,9476	0,9070	0,8984	0,8445	0,9443	0,9012	0,9576	0,9183	0,9127	0,8614	0,9430	0,9035	0,9805	0,9634	0,9707	0,9423	0,9592	0,9266	0,9597	0,9265
ResNet101	0,9479	0,9137	0,9452	0,9054	0,9445	0,9001	0,8868	0,8254	0,9544	0,9129	0,9061	0,8544	0,9391	0,8990	0,9796	0,9603	0,9714	0,9468	0,9618	0,9310	0,9652	0,9320
DarkNet19	0,9631	0,9281	0,9587	0,9216	0,9575	0,9166	0,9544	0,9129	0,9246	0,8734	0,9268	0,8758	0,9554	0,9160	0,9817	0,9599	0,9649	0,9316	0,9547	0,9138	0,9670	0,9341
DarkNet53	0,9200	0,8768	0,9211	0,8760	0,9127	0,8601	0,9062	0,8535	0,9268	0,8763	0,8240	0,7409	0,9112	0,8622	0,9696	0,9493	0,9555	0,9285	0,9368	0,9005	0,9434	0,9091
MobileNetV2	0,9518	0,9185	0,9379	0,8986	0,9430	0,9040	0,9392	0,8987	0,9553	0,9162	0,9114	0,8620	0,8832	0,8203	0,9812	0,9635	0,9729	0,9481	0,9623	0,9344	0,9663	0,9334
ShuffleNet	0,9848	0,9708	0,9802	0,9628	0,9806	0,9635	0,9796	0,9607	0,9818	0,9588	0,9696	0,9489	0,9812	0,9636	0,9702	0,9474	0,9881	0,9743	0,9825	0,9660	0,9862	0,9714
InceptionV3	0,9822	0,9612	0,9730	0,9487	0,9707	0,9428	0,9715	0,9470	0,9649	0,9303	0,9556	0,9279	0,9728	0,9486	0,9879	0,9744	0,9607	0,9225	0,9790	0,9550	0,9802	0,9540
DenseNet201	0,9739	0,9411	0,9604	0,9288	0,9593	0,9268	0,9617	0,9305	0,9545	0,9143	0,9372	0,8994	0,9622	0,9343	0,9826	0,9660	0,9790	0,9553	0,9509	0,9044	0,9767	0,9507
Xception	0,9718	0,9422	0,9684	0,9403	0,9597	0,9271	0,9650	0,9329	0,9670	0,9331	0,9434	0,9074	0,9664	0,9333	0,9862	0,9712	0,9801	0,9538	0,9767	0,9515	0,9498	0,8948

Çizelge 4.12. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Gizli katman nöron sayısı= 2000)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,9619	0,8147	0,9798	0,9074	0,9730	0,8910	0,9732	0,8888	0,9867	0,9141	0,9483	0,8343	0,9768	0,8953	0,9964	0,9683	0,9951	0,9516	0,9934	0,9306	0,9898	0,9218
ResNet18	0,9799	0,9078	0,9471	0,8233	0,9723	0,8815	0,9735	0,8816	0,9859	0,9060	0,9558	0,8421	0,9668	0,8712	0,9936	0,9584	0,9889	0,9355	0,9830	0,9121	0,9860	0,9254
ResNet50	0,9730	0,8903	0,9725	0,8806	0,9328	0,8021	0,9714	0,8722	0,9859	0,8996	0,9465	0,8206	0,9687	0,8737	0,9931	0,9587	0,9867	0,9264	0,9802	0,9048	0,9793	0,9034
ResNet101	0,9731	0,8872	0,9734	0,8821	0,9713	0,8725	0,9303	0,7768	0,9837	0,8936	0,9436	0,8080	0,9677	0,8684	0,9934	0,9558	0,9890	0,9319	0,9838	0,9149	0,9848	0,9141
DarkNet19	0,9866	0,9147	0,9860	0,9058	0,9859	0,9024	0,9838	0,8946	0,9667	0,8455	0,9681	0,8496	0,9845	0,8991	0,9954	0,9544	0,9882	0,9187	0,9839	0,8978	0,9900	0,9222
DarkNet53	0,9485	0,8357	0,9557	0,8422	0,9466	0,8216	0,9434	0,8077	0,9682	0,8476	0,8824	0,7082	0,9440	0,8195	0,9875	0,9405	0,9747	0,9029	0,9650	0,8659	0,9661	0,8764
MobileNetV2	0,9765	0,8962	0,9669	0,8727	0,9688	0,8732	0,9678	0,8704	0,9845	0,8974	0,9440	0,8199	0,9280	0,7756	0,9947	0,9582	0,9888	0,9342	0,9827	0,9177	0,9861	0,9133
ShuffleNet	0,9964	0,9684	0,9936	0,9576	0,9931	0,9576	0,9934	0,9552	0,9953	0,9539	0,9874	0,9412	0,9947	0,9589	0,9901	0,9393	0,9969	0,9716	0,9958	0,9632	0,9962	0,9684
InceptionV3	0,9951	0,9520	0,9890	0,9367	0,9867	0,9249	0,9890	0,9321	0,9882	0,9187	0,9747	0,9027	0,9889	0,9342	0,9968	0,9723	0,9833	0,9001	0,9944	0,9472	0,9939	0,9399
DenseNet201	0,9933	0,9307	0,9829	0,9120	0,9804	0,9041	0,9838	0,9138	0,9838	0,8984	0,9648	0,8649	0,9830	0,9183	0,9958	0,9636	0,9945	0,9483	0,9824	0,8834	0,9933	0,9385
Xception	0,9898	0,9250	0,9861	0,9249	0,9792	0,9038	0,9846	0,9137	0,9901	0,9225	0,9659	0,8768	0,9861	0,9130	0,9962	0,9687	0,9939	0,9390	0,9931	0,9391	0,9778	0,8677

Çizelge 4.7-4.12 genel olarak analiz edildiğinde birleştirilmiş veri kümeleri üzerinde veri setinin kendisiyle birleştirilmesi test performansında önemli bir artış sağlamadığı; RWN gizli katman nöron sayısının artmasıyla eğitim performansının arttığı görülmektedir. Ayrıca derin öğrenme modellerinde görece diğerlerine göre başarılı olan modeller ile çıkarılan özelliklerin birleştirme sonucunda da daha yüksek bir test başarıları gösterdiği görülmüştür. En yüksek eğitim başarısının RWN gizli katman nöron sayısının 2000 olarak alındığı ve ShuffleNet ve Inception mimarilerinden çıkarılan özelliklerin birleştirilmesi ile elde edildiği görülmüştür. En yüksek test başarıları ise RWN gizli katman nöron sayısının 500 veya 1000 olarak alındığı ve Inception ve ShuffleNet mimarilerinden çıkarılan özelliklerin birleştirilmesiyle elde edildiği görülmüştür. Birleştirilmiş veri setleri üzerindeki RWN performansına ait genel karşılaştırma Çizelge 4.13'te verilmiştir.

Çizelge 4.13. Birleştirilmiş veri setleri üzerinde farklı nöron sayıları ile genel başarı karşılaştırması

	RWN Gizli Katman Nöron Sayıları					
	50	100	250	500	1000	2000
En Yüksek Eğitim	0,9643	0,9706	0,9768	0,9816	0,9881	0,9969
En Yüksek Test	0,9630	0,9685	0,9725	0,9744	0,9744	0,9723
Ortalama Eğitim	0,9185	0,9262	0,9342	0,9420	0,9551	0,9783
Ortalama Test	0,9166	0,9227	0,9261	0,9259	0,9212	0,9014

Çizelge 4.13'ten görülen yukarıdaki deneylerin yanı sıra RWN'de aktivasyon fonksiyonları da performansa etki etmektedir. Çizelge 4.13'te verilen ortalama test başarıları dikkate alınarak ve gizli katman nöron sayısı 250 seçilerek bu fonksiyonların birleştirilmiş veri kümeleri üzerindeki performansları Çizelge 4.14-4.18'de verilmiştir. RWN'de 250 nöron ve Tanjant Sigmoid aktivasyon fonksiyonlarının yapıldığı deneyler zaten Çizelge 4.9'de verildiği için tekrar sunulmamıştır.

Çizelge 4.14. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Aktivasyon Fonksiyonu: Sigmoid)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8758	0,8593	0,9409	0,9340	0,9333	0,9268	0,9307	0,9231	0,9390	0,9306	0,9000	0,8919	0,9326	0,9251	0,9742	0,9703	0,9691	0,9649	0,9518	0,9445	0,9565	0,9512
ResNet18	0,9410	0,9336	0,8843	0,8755	0,9258	0,9154	0,9235	0,9140	0,9326	0,9240	0,8960	0,8856	0,9177	0,9088	0,9679	0,9630	0,9585	0,9524	0,9408	0,9338	0,9522	0,9461
ResNet50	0,9334	0,9265	0,9256	0,9148	0,8751	0,8640	0,9215	0,9113	0,9301	0,9194	0,8883	0,8754	0,9236	0,9149	0,9679	0,9630	0,9559	0,9492	0,9426	0,9343	0,9447	0,9382
ResNet101	0,9306	0,9230	0,9234	0,9138	0,9214	0,9109	0,8614	0,8512	0,9255	0,9147	0,8809	0,8706	0,9188	0,9108	0,9647	0,9596	0,9575	0,9516	0,9425	0,9343	0,9473	0,9396
DarkNet19	0,9391	0,9309	0,9326	0,9232	0,9303	0,9202	0,9253	0,9152	0,8936	0,8821	0,8947	0,8835	0,9288	0,9194	0,9643	0,9579	0,9398	0,9312	0,9268	0,9174	0,9432	0,9343
DarkNet53	0,9001	0,8917	0,8963	0,8870	0,8880	0,8767	0,8812	0,8703	0,8947	0,8830	0,7822	0,7612	0,8879	0,8771	0,9548	0,9495	0,9404	0,9344	0,9165	0,9094	0,9264	0,9190
MobileNetV2	0,9326	0,9259	0,9178	0,9092	0,9235	0,9150	0,9187	0,9109	0,9290	0,9194	0,8878	0,8776	0,8525	0,8406	0,9685	0,9642	0,9590	0,9536	0,9443	0,9384	0,9493	0,9424
ShuffleNet	0,9741	0,9703	0,9680	0,9635	0,9678	0,9632	0,9647	0,9594	0,9644	0,9580	0,9549	0,9487	0,9686	0,9644	0,9539	0,9483	0,9774	0,9740	0,9690	0,9643	0,9755	0,9712
InceptionV3	0,9691	0,9646	0,9585	0,9523	0,9561	0,9500	0,9573	0,9515	0,9397	0,9309	0,9404	0,9338	0,9592	0,9534	0,9773	0,9735	0,9394	0,9313	0,9626	0,9567	0,9665	0,9613
DenseNet201	0,9519	0,9447	0,9409	0,9337	0,9422	0,9353	0,9426	0,9352	0,9269	0,9182	0,9168	0,9095	0,9444	0,9382	0,9690	0,9645	0,9626	0,9567	0,9216	0,9119	0,9605	0,9550
Xception	0,9565	0,9512	0,9522	0,9461	0,9447	0,9384	0,9473	0,9395	0,9431	0,9355	0,9264	0,9188	0,9491	0,9423	0,9755	0,9715	0,9663	0,9619	0,9605	0,9552	0,9236	0,9121

Çizelge 4.15. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Aktivasyon Fonksiyonu: Sinus)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8689	0,8606	0,8112	0,7824	0,8339	0,8053	0,8715	0,8491	0,5963	0,5044	0,8705	0,8487	0,9149	0,9027	0,5964	0,5033	0,9502	0,9397	0,9074	0,8910	0,9430	0,9332
ResNet18	0,8117	0,7830	0,7774	0,7450	0,6998	0,6547	0,7329	0,6924	0,5968	0,5036	0,7741	0,7424	0,7574	0,7210	0,5964	0,5056	0,7688	0,7338	0,7464	0,7062	0,7819	0,7505
ResNet50	0,8339	0,8080	0,6968	0,6503	0,7869	0,7552	0,7679	0,7323	0,5962	0,5028	0,7779	0,7440	0,7905	0,7581	0,5962	0,5037	0,8049	0,7751	0,7823	0,7488	0,8107	0,7804
ResNet101	0,8724	0,8499	0,7335	0,6948	0,7672	0,7305	0,8266	0,8018	0,5960	0,5049	0,8021	0,7690	0,8301	0,8029	0,5960	0,5027	0,8547	0,8304	0,8230	0,7948	0,8573	0,8327
DarkNet19	0,5966	0,5058	0,5958	0,5025	0,5960	0,5050	0,5964	0,5018	0,5966	0,5049	0,5963	0,5023	0,5963	0,5036	0,5961	0,5022	0,5964	0,5020	0,5964	0,5038	0,5961	0,5008
DarkNet53	0,8700	0,8471	0,7736	0,7382	0,7778	0,7425	0,8006	0,7673	0,5961	0,5053	0,7705	0,7375	0,8364	0,8109	0,5962	0,5019	0,8823	0,8595	0,8454	0,8197	0,8756	0,8526
MobileNetV2	0,9147	0,9023	0,7575	0,7223	0,7898	0,7576	0,8304	0,8042	0,5963	0,5020	0,8360	0,8108	0,8473	0,8333	0,5962	0,5034	0,9056	0,8887	0,8622	0,8389	0,9058	0,8904
ShuffleNet	0,5956	0,5037	0,5960	0,5024	0,5967	0,5015	0,5969	0,5029	0,5967	0,5007	0,5966	0,5025	0,5961	0,5028	0,5963	0,5031	0,5966	0,5049	0,5966	0,5023	0,5971	0,5009
InceptionV3	0,9510	0,9419	0,7677	0,7325	0,8064	0,7759	0,8551	0,8288	0,5963	0,5052	0,8826	0,8602	0,9053	0,8887	0,5961	0,5038	0,9317	0,9246	0,8777	0,8562	0,9235	0,9089
DenseNet201	0,9071	0,8900	0,7447	0,7068	0,7827	0,7484	0,8218	0,7941	0,5966	0,5038	0,8454	0,8205	0,8614	0,8394	0,5964	0,5016	0,8746	0,8525	0,8862	0,8705	0,8812	0,8603
Xception	0,9433	0,9344	0,7789	0,7446	0,8102	0,7816	0,8576	0,8342	0,5962	0,5040	0,8763	0,8533	0,9051	0,8903	0,5963	0,5018	0,9230	0,9089	0,8816	0,8608	0,9174	0,9082

Çizelge 4.16. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Aktivasyon Fonksiyonu: Tribas)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8785	0,8516	0,9241	0,9146	0,9171	0,9075	0,9166	0,9076	0,6526	0,5954	0,8792	0,8702	0,9281	0,9207	0,9329	0,9188	0,9650	0,9593	0,9287	0,9132	0,9545	0,9466
ResNet18	0,9243	0,9146	0,8674	0,8566	0,8916	0,8771	0,8874	0,8745	0,7262	0,6838	0,8509	0,8365	0,8986	0,8863	0,9122	0,8973	0,9359	0,9268	0,9214	0,9106	0,9369	0,9271
ResNet50	0,9174	0,9080	0,8918	0,8775	0,8544	0,8436	0,8847	0,8705	0,7277	0,6844	0,8395	0,8227	0,9016	0,8911	0,9124	0,8960	0,9357	0,9267	0,9211	0,9111	0,9278	0,9184
ResNet101	0,9164	0,9060	0,8876	0,8748	0,8853	0,8720	0,8461	0,8364	0,7006	0,6525	0,8368	0,8208	0,8964	0,8868	0,9031	0,8865	0,9363	0,9277	0,9205	0,9099	0,9294	0,9198
DarkNet19	0,6524	0,5961	0,7260	0,6832	0,7266	0,6846	0,7015	0,6560	0,6374	0,5758	0,7117	0,6656	0,7013	0,6535	0,7312	0,6925	0,6839	0,6333	0,6459	0,5855	0,6975	0,6476
DarkNet53	0,8795	0,8694	0,8511	0,8349	0,8393	0,8230	0,8374	0,8207	0,7120	0,6675	0,7533	0,7380	0,8539	0,8405	0,8885	0,8716	0,9107	0,9017	0,8872	0,8774	0,9040	0,8947
MobileNetV2	0,9284	0,9203	0,8986	0,8867	0,9020	0,8896	0,8967	0,8858	0,7002	0,6541	0,8540	0,8417	0,8495	0,8400	0,9260	0,9116	0,9511	0,9441	0,9358	0,9275	0,9439	0,9367
ShuffleNet	0,9330	0,9184	0,9129	0,8986	0,9131	0,8987	0,9036	0,8874	0,7318	0,6893	0,8881	0,8718	0,9259	0,9119	0,8999	0,8820	0,9333	0,9203	0,9273	0,9141	0,9364	0,9235
InceptionV3	0,9649	0,9588	0,9361	0,9274	0,9355	0,9275	0,9359	0,9274	0,6843	0,6355	0,9103	0,9013	0,9515	0,9451	0,9335	0,9193	0,9322	0,9243	0,9540	0,9454	0,9621	0,9557
DenseNet201	0,9289	0,9133	0,9213	0,9103	0,9207	0,9098	0,9210	0,9102	0,6457	0,5851	0,8877	0,8778	0,9358	0,9274	0,9269	0,9121	0,9538	0,9453	0,8680	0,8441	0,9536	0,9454
Xception	0,9544	0,9463	0,9370	0,9272	0,9280	0,9198	0,9294	0,9200	0,6975	0,6492	0,9038	0,8941	0,9437	0,9369	0,9356	0,9228	0,9620	0,9553	0,9537	0,9460	0,9185	0,9068

Çizelge 4.17. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Aktivasyon Fonksiyonu: Radbas)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8769	0,8558	0,9325	0,9236	0,9246	0,9152	0,9243	0,9155	0,6780	0,6254	0,8885	0,8790	0,9308	0,9216	0,9548	0,9449	0,9675	0,9623	0,9412	0,9288	0,9562	0,9494
ResNet18	0,9324	0,9239	0,8749	0,8654	0,9063	0,8929	0,9033	0,8913	0,7668	0,7301	0,8680	0,8540	0,9081	0,8976	0,9408	0,9287	0,9474	0,9390	0,9308	0,9212	0,9452	0,9369
ResNet50	0,9248	0,9155	0,9059	0,8938	0,8632	0,8506	0,9009	0,8881	0,7661	0,7298	0,8572	0,8406	0,9117	0,9007	0,9401	0,9285	0,9447	0,9365	0,9299	0,9197	0,9357	0,9261
ResNet101	0,9241	0,9148	0,9031	0,8906	0,9006	0,8870	0,8540	0,8426	0,7365	0,6960	0,8552	0,8400	0,9074	0,8967	0,9313	0,9192	0,9460	0,9377	0,9303	0,9210	0,9380	0,9276
DarkNet19	0,6774	0,6249	0,7655	0,7295	0,7665	0,7320	0,7363	0,6959	0,6518	0,5936	0,7489	0,7100	0,7361	0,6957	0,7730	0,7368	0,7181	0,6746	0,6669	0,6140	0,7328	0,6931
DarkNet53	0,8889	0,8792	0,8683	0,8542	0,8571	0,8404	0,8553	0,8397	0,7481	0,7111	0,7636	0,7465	0,8666	0,8543	0,9158	0,9030	0,9232	0,9139	0,8990	0,8893	0,9144	0,9055
MobileNetV2	0,9309	0,9224	0,9079	0,8979	0,9113	0,9002	0,9072	0,8958	0,7355	0,6954	0,8663	0,8536	0,8521	0,8399	0,9491	0,9389	0,9551	0,9486	0,9395	0,9326	0,9469	0,9388
ShuffleNet	0,9543	0,9454	0,9408	0,9280	0,9397	0,9292	0,9318	0,9192	0,7735	0,7399	0,9154	0,9023	0,9490	0,9384	0,9284	0,9150	0,9560	0,9463	0,9495	0,9397	0,9584	0,9494
InceptionV3	0,9676	0,9618	0,9472	0,9387	0,9447	0,9357	0,9461	0,9375	0,7170	0,6720	0,9232	0,9149	0,9552	0,9487	0,9562	0,9462	0,9357	0,9266	0,9580	0,9510	0,9649	0,9582
DenseNet201	0,9415	0,9286	0,9308	0,9214	0,9306	0,9200	0,9301	0,9202	0,6674	0,6140	0,8992	0,8900	0,9398	0,9320	0,9493	0,9388	0,9578	0,9515	0,8921	0,8724	0,9568	0,9490
Xception	0,9562	0,9493	0,9456	0,9366	0,9357	0,9271	0,9381	0,9288	0,7328	0,6923	0,9144	0,9052	0,9468	0,9385	0,9584	0,9494	0,9647	0,9587	0,9568	0,9495	0,9232	0,9079

Çizelge 4.18. Birleştirilmiş veri kümeleri üzerinde RWN'nin performansı (Aktivasyon Fonksiyonu: Hardlim)

Özellik Çıkarılan Mimari	EfficientNet		ResNet18		ResNet50		ResNet101		DarkNet19		DarkNet53		MobileNetV2		ShuffleNet		InceptionV3		DenseNet201		Xception	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
EfficientNet	0,8819	0,8521	0,9369	0,9301	0,9298	0,9242	0,9280	0,9203	0,9374	0,9281	0,8936	0,8874	0,9308	0,9239	0,9730	0,9685	0,9678	0,9629	0,9506	0,9419	0,9566	0,9518
ResNet18	0,9368	0,9302	0,8788	0,8724	0,9202	0,9110	0,9181	0,9098	0,9313	0,9218	0,8880	0,8799	0,9133	0,9057	0,9666	0,9620	0,9540	0,9479	0,9366	0,9296	0,9493	0,9435
ResNet50	0,9300	0,9235	0,9200	0,9113	0,8689	0,8614	0,9153	0,9072	0,9284	0,9183	0,8785	0,8693	0,9183	0,9115	0,9664	0,9617	0,9517	0,9463	0,9376	0,9305	0,9415	0,9363
ResNet101	0,9281	0,9210	0,9182	0,9093	0,9161	0,9072	0,8552	0,8475	0,9233	0,9118	0,8732	0,8633	0,9132	0,9048	0,9633	0,9577	0,9529	0,9471	0,9377	0,9316	0,9437	0,9370
DarkNet19	0,9375	0,9282	0,9311	0,9214	0,9283	0,9172	0,9230	0,9125	0,8936	0,8826	0,8940	0,8816	0,9275	0,9167	0,9634	0,9565	0,9372	0,9278	0,9249	0,9152	0,9415	0,9328
DarkNet53	0,8932	0,8866	0,8880	0,8795	0,8788	0,8684	0,8732	0,8635	0,8940	0,8815	0,7623	0,7508	0,8772	0,8689	0,9527	0,9478	0,9324	0,9275	0,9084	0,9019	0,9212	0,9160
MobileNetV2	0,9310	0,9236	0,9132	0,9062	0,9185	0,9118	0,9133	0,9057	0,9272	0,9165	0,8770	0,8688	0,8506	0,8424	0,9673	0,9631	0,9555	0,9506	0,9410	0,9352	0,9469	0,9414
ShuffleNet	0,9730	0,9687	0,9665	0,9615	0,9664	0,9615	0,9632	0,9577	0,9632	0,9569	0,9526	0,9467	0,9673	0,9627	0,9534	0,9473	0,9759	0,9712	0,9679	0,9631	0,9744	0,9704
InceptionV3	0,9678	0,9627	0,9539	0,9486	0,9515	0,9467	0,9528	0,9478	0,9374	0,9278	0,9324	0,9277	0,9556	0,9503	0,9760	0,9721	0,9331	0,9260	0,9603	0,9548	0,9650	0,9600
DenseNet201	0,9507	0,9420	0,9369	0,9299	0,9375	0,9309	0,9377	0,9309	0,9251	0,9147	0,9086	0,9022	0,9412	0,9355	0,9679	0,9629	0,9604	0,9547	0,9181	0,9057	0,9585	0,9524
Xception	0,9566	0,9506	0,9493	0,9439	0,9417	0,9367	0,9435	0,9369	0,9415	0,9327	0,9211	0,9156	0,9468	0,9411	0,9746	0,9700	0,9649	0,9602	0,9585	0,9524	0,9187	0,9095

Çizelge 4.9 ve Çizelge 4.14-4.18 genel olarak analiz edildiğinde Sigmoid, Tanjant Sigmoid ve Hardlimit aktivasyon fonksiyonları kullanıldığında benzer başarılar elde edilmiştir. Sinus, Tribas ve Radbas aktivasyon fonksiyonları kullanıldığında ortalama eğitim ve test başarıları %90'ın altında kalmıştır. En yüksek eğitim başarıları ve test başarıları sırasıyla %97,74 ve %97,40 olarak Inception ve ShuffleNet modellerinden çıkarılan özelliklerin birleştirilmesiyle RWN'de Sigmoid aktivasyon fonksiyonu kullanılarak elde edilmiştir. Ortalama eğitim ve test başarılarında da yine Sigmoid aktivasyonu fonksiyonu kullanıldığında sırasıyla %93,54 ve %92,77 değerlerine ulaşılmıştır. Genel bir karşılaştırma Çizelge 4.19'da sunulmuştur.

Çizelge 4.19. Birleştirilmiş veri setleri üzerinde farklı aktivasyon fonksiyonları ile genel başarı karşılaştırması

	Sig	Tansig	Sin	Tribas	Radbas	Hardlimit
En İyi Eğitim	0,9774	0,9768	0,9510	0,9650	0,9676	0,9760
En İyi Test	0,9740	0,9725	0,9419	0,9593	0,9623	0,9721
Ortalama Eğitim	0,9354	0,9342	0,7568	0,8732	0,8889	0,9319
Ortalama Test	0,9277	0,9261	0,7088	0,8552	0,8730	0,9246

Çizelge 4.19, Sigmoid ve Tangent Sigmoid aktivasyon fonksiyonlarının genellikle diğerlerinden daha iyi performans gösterdiğini göstermektedir. Hardlimit fonksiyonu da yüksek başarı elde etmiştir. Öte yandan, Sine, Tribas ve Radbas fonksiyonları, özellikle ortalama test doğrulukları açısından, nispeten daha düşük performans göstermişlerdir.

5. SONUÇLAR VE ÖNERİLER

X-ray güvenlik tarama içerdiği zorluklar nedeniyle oldukça zor bir problem olarak ele alınmaktadır. Özellikle sınıflandırma ve tespit problemleri çanta, koli vb. içeriklerinin çeşitliliği ve X-ray görüntüsünün doğasında var olan üst üste binme gibi sebepler nedeniyle daha da zor hale gelmektedir. Bunun dışında ilgili görüntülerde bulunan çok sayıda eşyanın standart olmayan biçimlerde (açı, uzaklık, üst üste binme) bir araya gelmesi nedeniyle içerdiği varyasyon miktarı oldukça yüksektir. Bu problemin özel bir alt kümesi olarak ele aldığımız dizüstü bilgisayar görüntülerinin içerisinde ilgili cihaza ait olmayan patlayıcı devresi olarak kullanılabilecek devrelerin de tespiti de benzer sorunlar nedeniyle zor bir problemdir. Dizüstü bilgisayar devre tasarımlarının farklılıkları ve tespit edilmesi gereken devrelerin içerik açısından mevcut devrelere benzerlik göstermesi nedeniyle, sınıf içindeki varyasyon yüksek, sınıflar arası varyasyon ise düşüktür. Sahip olduğu bu özellikler nedeniyle ilgili problem yapay zekâ yöntemlerini oldukça zorlamaktadır.

5.1 Sonuçlar

Bu tezin amacı, özellikle güvenlik riskinin en yüksek olduğu havalimanları gibi yerlerde, tehlikeli madde tespitini otomatikleştirerek güvenlik açıklarını en aza indirmektir. Bu amaçla, daha önce literatürde yer almayan dizüstü bilgisayarlar içindeki patlayıcı devresi olabilecek devrelerin tespiti yapılmıştır. Bu süreçte ilk önce ikinci el bilgisayar ve devreler satın alınarak amaca uygun özgün bir veri seti oluşturulmuştur. Ancak zaman ve maliyet gibi kısıtlamalar nedeniyle, oluşturulan veri setinin küçüklüğünden ötürü, denenen derin öğrenme yöntemleri aşırı öğrenme durumuna maruz kalmıştır. Bu durumu azaltmak için akla gelen ilk yöntem veri artırımı olsa da gerçek dünya örneklerinin yukarıda bahsedilen maliyet ve zaman nedenleriyle artırımı mantıklı görülmemiştir. Yapay olarak artırmak ise dizüstü bilgisayar devrelerinin yapısal karmaşıklığı nedeniyle tercih edilmemiştir.

Veri seti oluşturulduktan sonra ilk aşamada veri seti üzerinde sınıflandırma amacıyla yöntemler 10 katlı çapraz doğrulama ile eğitilerek başarıları incelenmiştir. Eğitim veri kümesi üzerinde modellerin çoğunluğu %85 üzeri başarı göstermiştir. EfficientNet, ShuffleNet, Xception gibi modeller ise başarı olarak %95 üzerine çıkabilmişlerdir. Ancak veri setinin boyutunun ufak, karmaşıklığının yüksek olması

nedeniyle, yapılan test kümesi deneylerinde ilgili başarılar Inception, DenseNet, DarkNet19 ve ShuffleNet yöntemlerinin dışında %70'ten daha aşağı düşmüştür. Bunun da sebebi veri seti boyutu ve karmaşıklığından ötürü yöntemlerin aşırı ezberleme yapmasıdır. Mevcut yöntemlerin başarımının artırılması ve aşırı öğrenme durumunun giderilmesi için alternatif yöntemler araştırılmış ve özellik birleştirme yöntemlerinden sonradan özellik füzyonun da karar kılınmıştır. Bu birleştirme işlemini gerçekleştirdikten sonra sınıflandırma aşaması için tam bağlı bir ağ yerine global ortalama havuzlama benzeri bir yöntem kullanılarak aşırı öğrenme üstesinden gelinmesi doğru bulunmuştur. Bu amaçla hem eğitim süresinin tek adımdan oluşması hem de aşırı öğrenmeye karşı direnci nedeniyle RWN seçilmiş ve süreçte kullanılmıştır. Karar verilen bu birleştirme ve sınıflandırma yönteminin etkinliği yapılan deneylerle incelenmiştir. Bu deneyler sınıflandırıcı olarak RWN'nin kullanıldığı birleştirme olmadan gerçekleştirilen, ayrıca sınıflandırma ve özellik füzyonunun birlikte kullanıldığı deney düzenekleridir. Birleştirme yapılmayan ayarda RWN'nin katman sayıları değiştirilerek gerçekleştirilen deneylerde, performansın tüm modellerde arttığı gözlemlenmiştir. Bu yöntemlerden en başarılısı 250 gizli katman nöron sayısında test başarısı %83,55'ten %94,82'e çıkan ShuffleNet olmuştur. Sonraki aşamada deneylerde birleştirme kullanılmıştır. Burada yine RWN'nin farklı parametre değerlerine göre kıyaslanması da araştırılmıştır. Bunlar sırasıyla aktivasyon fonksiyonu ve gizli katman nöron sayısıdır. Yapılan bu deney sonuçlarına göre en yüksek test başarıları %94,82 'den %97,40'a yükseltilmiştir. Bu başarıyı Inception ve ShuffleNet modellerinden çıkarılan özelliklerin birleştirilmesi, RWN'de ise Sigmoid aktivasyon fonksiyonunun kullanılması şeklinde yapılan deney düzeneği vermiştir.

5.2 Öneriler

Derin öğrenme, X-ray güvenlik taramalarında büyük başarılar elde etmektedir. Literatürde yer alan çalışmalar incelendiğinde, yeni çıkan farklı yöntemler kullanılarak başarılar artırılmaya çalışılmaktadır. Bu artırım da kullanılan yöntemin derinlik ve temsil kabiliyetine bağlı olmaktadır. Ayrıca veri seti boyutu, karmaşıklığı gibi unsurlarda başarıya etki etmektedir. Literatürde bulunan birkaç veri seti dışında çok azı gerçek dünya örneklerinden toplanmıştır. Bu nedenle yapılan çalışmalar, yöntemler başarı gösterse de gerçek dünyada kullanımında ekstra işlemler gerekmektedir.

Sonuç olarak elde edilen yöntemler bunların birleşiminin bir sonucudur. Tez kapsamında yapılan bu işlemlerin dışında başarıyı artırmak için farklı işlemler gerçekleştirilebilir. Örneğin gerçek dünyada kullanılan bilgisayar veya X-ray sistemlerinin talep ettiği hesaplama kabiliyetleri düşünülerek mevcut yöntemlerin içerdiği gereksiz özellikler sonradan işleme (post processing) gibi işlemler yapılarak azaltılabilir. Bunlar elde edilen modellerin damıtma (distilling), budama (pruning) gibi sıkıştırma yöntemler ile küçültülmesi olabileceği gibi ABC vb. optimizasyon algoritmaları vasıtasıyla özellik sayılarının düşürülmesi de olabilir. Ayrıca aşırı ezberleme kaçınma (overfitting avoiding) teknikleri denenerek aşırı öğrenmenin üstesinden gelinmeye çalışılabilir.

Bu yöntemlerin dışında modellerin gerçek dünyada daha başarıyla kullanılabilmesi için veri setine ve modellerine kalibrasyon benzeri yöntemler yapılarak iyileştirmeler gerçekleştirilebilir.

Ayrıca tez çalışmasında ulaşılan başarı oranları veri setinin küçüklüğü ve karmaşıklığı nedeniyle yeterli görülmemelidir. Özellikle veri setinin küçüklüğü göz önünde bulundurularak modellerin sahip olabileceği aşırı öğrenme durumunun üstesinden gelmek amacıyla veri setinin doğal veya yapay olarak artırılması sağlanabilir. Bunun için yapılacak çalışmalarda özellikle yapay görüntülerin GAN tabanlı yöntemlerle elde edilme süreci takip edilebilir. Ancak bu süreci zorlaştıran problemler bulunmaktadır. Özellikle dizüstü bilgisayar devrelerinin yapılarının karmaşık olması, ayrıca X-ray görüntülerinin yapısından kaynaklanan doku gibi bilgilerin azlığı ilgili problemlere örnek olarak verilebilir. Bunun dışında, sonraki çalışmalarda dizüstü bilgisayar görüntüleri segmentasyon algoritmaları ile bölümlenmeye tabi tutulup, içerdiği devre elemanlarıyla ilgili bilgiler mevcut yöntemlerle birlikte kullanılarak, anomali tespiti başarı oranının artırılmasında fayda sağlanabilir. Burada işlemci, harddisk, ram vb. alt alanlara bölünen yapı bireysel veya toplu olarak ek bilgi sağlamak amacıyla anomali tespitinde kullanılabilir. Ancak bunu yaparken X-ray görüntülerinin birden fazla üst üste binen nesnelerden oluştuğu yani bir pikselin üst üste binmeden oluştuğu göz önünde bulundurulmalıdır. Ayrıca, ağırlık katman ve derinlik gibi parametrelerinin otomatik yöntemlerle, aşağıdan yukarıya doğru oluşturulması sayesinde, ağ modelleri için optimuma yakın bir yapı elde edilebilir. Bu çalışmada kullanılan veri setinin karmaşıklığının fazla olması nedeniyle ona daha uygun bir model karmaşıklığı elde edilerek aşırı öğrenme durumunun üstesinden gelinebilir. Ayrıca aşırı öğrenme durumunu engellemek adına fazla ağırlıkların kaldırılması, ikinci derece eğim bilgisi ile gereksiz

parametrelerin azaltılması, doku deformasyonu (pattern deformation) gibi yöntemler denenerek modellerin genelleme kabiliyetleri artırılabilir. Bunun dışında, veri seti X-ray görüntülerinden oluşmaktadır. Görüntüler, farklı açı ve uzaklık gibi sebeplerle değişim gösterdiğinden, bu durum ilgili görüntülerin standart olmayan bir yapıda olmasına neden olmaktadır. Ayrıca görüntülerin üst üste binmelerden ötürü değişmesi sebebiyle veri seti çok fazla gürültü içermektedir. Bu sebeple sonraki yapılacak çalışmalarda bu gürültüyü azaltmaya çalışan yöntemler kullanılabilir.



KAYNAKLAR

- Ackley, D. H., Hinton, G. E. ve Sejnowski, T. J., 1985, A learning algorithm for Boltzmann machines, *Cognitive science*, 9 (1), 147-169.
- Akcay, S. ve Breckon, T. P., 2017, An evaluation of region based object detection strategies within x-ray baggage security imagery, *2017 IEEE International Conference on Image Processing (ICIP)*, 1337-1341.
- Akcay, S., Atapour-Abarghouei, A. ve Breckon, T. P., 2018a, Ganomaly: Semi-supervised anomaly detection via adversarial training, *Asian conference on computer vision*, 622-637.
- Akcay, S., Kundegorski, M. E., Willcocks, C. G. ve Breckon, T. P., 2018b, Using deep convolutional neural network architectures for object classification and detection within x-ray baggage security imagery, *IEEE transactions on information forensics and security*, 13 (9), 2203-2215.
- Akçay, S., Kundegorski, M. E., Devereux, M. ve Breckon, T. P., 2016, Transfer learning using convolutional neural networks for object classification within x-ray baggage security imagery, *2016 IEEE International Conference on Image Processing (ICIP)*, 1057-1061.
- Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Van Esesn, B. C., Awwal, A. A. S. ve Asari, V. K., 2018, The history began from alexnet: A comprehensive survey on deep learning approaches, *arXiv preprint arXiv:1803.01164*.
- Andrews, J. T., Jaccard, N., Rogers, T. W. ve Griffin, L. D., 2017, Representation-learning for anomaly detection in complex x-ray cargo imagery, *Anomaly Detection and Imaging with X-Rays (ADIX) II*, 101870E.
- Avni, U., Goldberger, J., Sharon, M., Konen, E. ve Greenspan, H., 2010a, Chest x-ray characterization: from organ identification to pathology categorization, *Proceedings of the international conference on Multimedia information retrieval*, 155-164.
- Avni, U., Greenspan, H., Konen, E., Sharon, M. ve Goldberger, J., 2010b, X-ray categorization and retrieval on the organ and pathology level, using patch-based visual words, *IEEE transactions on medical imaging*, 30 (3), 733-746.
- Benedykciuk, E., Denkowski, M. ve Dmitruk, K., 2021, Material classification in X-ray images based on multi-scale CNN, *Signal, Image and Video Processing*, 1-9.
- Benjamin, R. ve Prakoonwit, S., 1997, Automatic X-ray screening of aircraft hold luggage.
- Benyahia, S., Meftah, B. ve Lézoray, O., 2022, Multi-features extraction based on deep learning for skin lesion classification, *Tissue and Cell*, 74, 101701.
- Berkeley, I. S. N., 1997, A Revisionist History of Connectionism, <https://userweb.ucs.louisiana.edu/~isb9112/dept/phil341/histconn.html>: [11.03.2024].
- Bhowmik, N., Gaus, Y. F. A., Akçay, S., Barker, J. W. ve Breckon, T. P., 2019a, On the impact of object and sub-component level segmentation strategies for supervised anomaly detection within x-ray security imagery, *2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA)*, 986-991.
- Bhowmik, N., Gaus, Y. F. A. ve Breckon, T. P., 2019b, Using deep neural networks to address the evolving challenges of concealed threat detection within complex electronic items, *2019 IEEE International Symposium on Technologies for Homeland Security (HST)*, 1-6.
- Bhowmik, N., Wang, Q., Gaus, Y. F. A., Szarek, M. ve Breckon, T. P., 2019c, The good, the bad and the ugly: Evaluating convolutional neural networks for

- prohibited item detection using real and synthetically composited X-ray imagery, *arXiv preprint arXiv:1909.11508*.
- Caldwell, M., Ransley, M., Rogers, T. W. ve Griffin, L. D., 2017, Transferring x-ray based automated threat detection between scanners with different energies and resolution, *Counterterrorism, Crime Fighting, Forensics, and Surveillance Technologies*, 104410F.
- Caldwell, M. ve Griffin, L. D., 2019, Limits on transfer learning from photographic image data to X-ray threat detection, *Journal of X-ray science and technology*, 27 (6), 1007-1020.
- Cao, C., Huang, Y., Yang, Y., Wang, L., Wang, Z. ve Tan, T., 2018, Feedback convolutional neural network for visual localization and segmentation, *IEEE transactions on pattern analysis and machine intelligence*, 41 (7), 1627-1640.
- Chang, A., Zhang, Y., Zhang, S., Zhong, L. ve Zhang, L., 2022, Detecting prohibited objects with physical size constraint from cluttered X-ray baggage images, *Knowledge-Based Systems*, 237, 107916.
- Cheng, G. ve Han, J., 2016, A survey on object detection in optical remote sensing images, *ISPRS journal of photogrammetry and remote sensing*, 117, 11-28.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Chouai, M., Merah, M. ve Mimi, M., 2020, CH-Net: Deep adversarial autoencoders for semantic segmentation in X-ray images of cabin baggage screening at airports, *Journal of Transportation Security*, 13 (1), 71-89.
- Dumagpi, J. K., Jung, W.-Y. ve Jeong, Y.-J., 2020, A new GAN-based anomaly detection (GBAD) approach for multi-threat object classification on large-scale x-ray security images, *IEICE TRANSACTIONS on Information and Systems*, 103 (2), 454-458.
- Dumagpi, J. K. ve Jeong, Y.-J., 2021a, Evaluating GAN-Based Image Augmentation for Threat Detection in Large-Scale Xray Security Images, *Applied Sciences*, 11 (1), 36.
- Dumagpi, J. K. ve Jeong, Y.-J., 2021b, Pixel-Level Analysis for Enhancing Threat Detection in Large-Scale X-ray Security Images, *Applied Sciences*, 11 (21), 10261.
- Flitton, G., Breckon, T. P. ve Megherbi, N., 2013, A comparison of 3D interest point descriptors with application to airport baggage object detection in complex CT imagery, *Pattern Recognition*, 46 (9), 2420-2436.
- Franzel, T., Schmidt, U. ve Roth, S., 2012, Object detection in multi-view X-ray images, *Joint DAGM (German association for pattern recognition) and OAGM symposium*, 144-154.
- Gaus, Y. F. A., Bhowmik, N., Akcay, S. ve Breckon, T., 2019a, Evaluating the transferability and adversarial discrimination of convolutional neural networks for threat object detection and classification within x-ray security imagery, *2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA)*, 420-425.
- Gaus, Y. F. A., Bhowmik, N., Akçay, S., Guillén-Garcia, P. M., Barker, J. W. ve Breckon, T. P., 2019b, Evaluation of a dual convolutional neural network architecture for object-wise anomaly detection in cluttered X-ray security imagery, *2019 International Joint Conference on Neural Networks (IJCNN)*, 1-8.

- Girshick, R., Donahue, J., Darrell, T. ve Malik, J., 2014, Rich feature hierarchies for accurate object detection and semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 580-587.
- Griffin, L. D., Caldwell, M., Andrews, J. T. ve Bohler, H., 2018, “unexpected item in the bagging area”: Anomaly detection in x-ray security images, *IEEE transactions on information forensics and security*, 14 (6), 1539-1553.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S. ve Lew, M. S., 2016, Deep learning for visual understanding: A review, *Neurocomputing*, 187, 27-48.
- Hardalaç, F., Uysal, F., Peker, O., Çiçeklidağ, M., Tolunay, T., Tokgöz, N., Kutbay, U., Demirciler, B. ve Mert, F., 2022, Fracture detection in wrist X-ray images using deep learning-based object detection models, *Sensors*, 22 (3), 1285.
- Hassanpour, R., 2016, Illicit Material Detection using Dual-Energy X-Ray Images, *International Arab Journal of Information Technology (IAJIT)*, 13 (4).
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Hochreiter, S., 1997, Long Short-term Memory, *Neural Computation MIT-Press*.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. ve Adam, H., 2017, Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv:1704.04861*.
- Huang, G.-B., Zhu, Q.-Y. ve Siew, C.-K., 2004, Extreme learning machine: a new learning scheme of feedforward neural networks, *2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541)*, 985-990.
- Huang, G.-B., Zhu, Q.-Y. ve Siew, C.-K., 2006, Extreme learning machine: theory and applications, *Neurocomputing*, 70 (1-3), 489-501.
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q., 2017, Densely connected convolutional networks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708.
- Huang, G., Liu, S., Van der Maaten, L. ve Weinberger, K. Q., 2018, Condensenet: An efficient densenet using learned group convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2752-2761.
- Ioannou, D., 2008, Methods for explosive detection with multiresolution computed tomography data, Google Patents.
- Jain, D. K., 2019, An evaluation of deep learning based object detection strategies for threat object detection in baggage security imagery, *pattern recognition letters*, 120, 112-119.
- Janiesch, C., Zschech, P. ve Heinrich, K., 2021, Machine learning and deep learning, *Electronic Markets*, 31 (3), 685-695.
- Karunakaran, C., Jayas, D. ve White, N., 2004, Identification of wheat kernels damaged by the red flour beetle using X-ray images, *Biosystems Engineering*, 87 (3), 267-274.
- Kim, S.-H., Lee, J.-H., Ko, B. ve Nam, J.-Y., 2010, X-ray image classification using random forests with local binary patterns, *2010 International Conference on Machine Learning and Cybernetics*, 3190-3194.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.

- Liang, K. J., Sigman, J. B., Spell, G. P., Strellis, D., Chang, W., Liu, F., Mehta, T. ve Carin, L., 2019, Toward automatic threat recognition for airport X-ray baggage screening with deep convolutional object detection, *arXiv preprint arXiv:1912.06329*.
- Lim, S. E., Xing, Y., Chen, Y., Leow, W. K., Howe, T. S. ve Png, M. A., 2004, Detection of femur and radius fractures in x-ray images, *Proc. 2nd Int. Conf. on Advances in Medical Signal and Info. Proc.*
- Liu, D., Liu, J., Yuan, P. ve Yu, F., 2022a, A data augmentation method for prohibited item X-ray pseudocolor images in X-ray security inspection based on wasserstein generative adversarial network and spatial-and-channel attention block, *Computational intelligence and neuroscience*, 2022.
- Liu, D., Liu, J., Yuan, P. ve Yu, F., 2022b, A Lightweight Dangerous Liquid Detection Method Based on Depthwise Separable Convolution for X-Ray Security Inspection, *Computational intelligence and neuroscience*, 2022.
- Liu, J., Leng, X. ve Liu, Y., 2019, Deep convolutional neural network based object detector for X-Ray baggage security imagery, *2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*, 1757-1761.
- Liu, R., Freund, Y. ve Spraggon, G., 2008, Image-based crystal detection: a machine-learning approach, *Acta Crystallographica Section D: Biological Crystallography*, 64 (12), 1187-1195.
- Liu, W., Shan, S., Chen, H., Wang, R., Sun, J. ve Zhou, Z., 2022c, X-ray weld defect detection based on AF-RCNN, *Welding in the World*, 66 (6), 1165-1177.
- Liu, Z., Li, J., Shu, Y. ve Zhang, D., 2018, Detection and recognition of security detection object based on YOLO9000, *2018 5th International Conference on Systems and Informatics (ICSAI)*, 278-282.
- Lowe, D. ve Broomhead, D., 1988, Multivariable functional interpolation and adaptive networks, *Complex systems*, 2 (3), 321-355.
- Ma, B., Jia, T., Su, M., Jia, X., Chen, D. ve Zhang, Y., 2022a, Automated Segmentation of Prohibited Items in X-ray Baggage Images Using Dense De-overlap Attention Snake, *IEEE Transactions on Multimedia*.
- Ma, C., Zhuo, L., Li, J., Zhang, Y. ve Zhang, J., 2022b, EAOD-Net: Effective anomaly object detection networks for X-ray images, *IET Image Processing*.
- Ma, N., Zhang, X., Zheng, H.-T. ve Sun, J., 2018, Shufflenet v2: Practical guidelines for efficient cnn architecture design, *Proceedings of the European conference on computer vision (ECCV)*, 116-131.
- Mahdavi, Y., 2009, Methods and apparatus for detecting objects in baggage, Google Patents.
- MathWorks, 26.10.2024, What Is Deep Learning? 3 things you need to know, <https://www.mathworks.com/discovery/deep-learning.html>: [26.10.2024].
- McCulloch, W. S. ve Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *The bulletin of mathematical biophysics*, 5, 115-133.
- Mery, D., 2011, Automated detection in complex objects using a tracking algorithm in multiple X-ray views, *CVPR 2011 WORKSHOPS*, 41-48.
- Mery, D., Lillo, I., Loebel, H., Rizzo, V., Soto, A., Cipriano, A. ve Aguilera, J. M., 2011, Automated fish bone detection using X-ray imaging, *Journal of Food Engineering*, 105 (3), 485-492.
- Mery, D., Rizzo, V., Zuccar, I. ve Pieringer, C., 2013, Automated X-ray object recognition using an efficient search algorithm in multiple views, *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, 368-374.

- Mery, D., Svec, E., Arias, M., Riffo, V., Saavedra, J. M. ve Banerjee, S., 2016, Modern computer vision techniques for x-ray testing in baggage inspection, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 47 (4), 682-692.
- Mery, D., Kamnietzky, A., Golborne, L., Figueroa, S. ve Saavedra, D., 2022, Target Detection by Target Simulation in X-ray Testing, *Journal of Nondestructive Evaluation*, 41 (1), 1-12.
- Miao, C., Xie, L., Wan, F., Su, C., Liu, H., Jiao, J. ve Ye, Q., 2019, Sixray: A large-scale security inspection x-ray benchmark for prohibited item discovery in overlapping images, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2119-2128.
- Minsky, M. ve Papert, S., 1969, Perceptrons. Massachusetts, MIT Press.
- Morris, T., Chien, T. ve Goodman, E., 2018, Convolutional neural networks for automatic threat detection in security X-Ray images, *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 285-292.
- Mueen, A., Baba, S. ve Zainuddin, R., 2007, Multilevel feature extraction and X-ray image classification, *Journal of Applied Sciences*, 7 (8), 1224-1229.
- Nguyen, H. D., Cai, R., Zhao, H., Kot, A. C. ve Wen, B., 2022, Towards More Efficient Security Inspection via Deep Learning: A Task-Driven X-ray Image Cropping Scheme, *Micromachines*, 13 (4), 565.
- Pao, Y.-H. ve Takefuji, Y., 1992, Functional-link net computing: theory, system architecture, and functionalities, *Computer*, 25 (5), 76-79.
- Petrozziello, A. ve Jordanov, I., 2019, Automated deep learning for threat detection in luggage from X-ray images, *International Symposium on Experimental Algorithms*, 505-512.
- Pieringer, C. ve Mery, D., 2010, Flaw detection in aluminium die castings using simultaneous combination of multiple views, *Insight-Non-Destructive Testing and Condition Monitoring*, 52 (10), 548-552.
- Poudel, U., 2019, InceptionNet, <https://medium.com/@ujjawalpoudel/inceptionnet-c6b5aa40eccf>: [21.03.2024].
- Rawat, W. ve Wang, Z., 2017, Deep convolutional neural networks for image classification: A comprehensive review, *Neural computation*, 29 (9), 2352-2449.
- Redmon, J. ve Farhadi, A., 2017, YOLO9000: better, faster, stronger. In proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7263-7271).
- Redmon, J. ve Farhadi, A., 2018, Yolov3: An incremental improvement, *arXiv preprint arXiv:1804.02767*.
- Rosenblatt, F., 1958, The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological review*, 65 (6), 386.
- Roy, A. G., Navab, N. ve Wachinger, C., 2018, Concurrent spatial and channel ‘squeeze & excitation’ in fully convolutional networks, *International conference on medical image computing and computer-assisted intervention*, 421-429.
- Saavedra, D., Banerjee, S. ve Mery, D., 2020, Detection of threat objects in baggage inspection with X-ray images using deep learning, *Neural Computing and Applications*, 1-17.
- Sani, S., Wiratunga, N. ve Massie, S., 2017, Learning deep features for kNN-based human activity recognition.
- Saunders, C., Gammerman, A. ve Vovk, V., 1998, Ridge regression learning algorithm in dual variables.

- Schmidt-Hackenberg, L., Yousefi, M. R. ve Breuel, T. M., 2012, Visual cortex inspired features for object detection in X-ray images, *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*, 2573-2576.
- Schmidt, W. F., Kraaijveld, M. A. ve Duin, R. P., 1992, Feed forward neural networks with random weights, *International conference on pattern recognition*, 1-1.
- Seok, J., Hyun, B., Kasa-Vubu, J. ve Girard, A., 2012, Automated classification system for bone age X-ray images, *2012 IEEE international conference on systems, man, and cybernetics (SMC)*, 208-213.
- Shaheed, K., Mao, A., Qureshi, I., Kumar, M., Hussain, S., Ullah, I. ve Zhang, X., 2022, DS-CNN: A pre-trained Xception model based on depth-wise separable convolutional neural network for finger vein recognition, *Expert Systems with Applications*, 191, 116288.
- Shao, F., Liu, J., Wu, P., Yang, Z. ve Wu, Z., 2022, Exploiting foreground and background separation for prohibited item detection in overlapping X-Ray images, *Pattern Recognition*, 122, 108261.
- Sigman, J. B., Spell, G. P., Liang, K. J. ve Carin, L., 2020, Background adaptive faster R-CNN for semi-supervised convolutional object detection of threats in x-ray images, *Anomaly Detection and Imaging with X-Rays (ADIX) V*, 1140404.
- Singh, J., Thakur, D., Ali, F., Gera, T. ve Kwak, K. S., 2020, Deep feature extraction and classification of android malware images, *Sensors*, 20 (24), 7013.
- Singh, S. ve Singh, M., 2003, Explosives detection systems (EDS) for aviation security, *Signal processing*, 83 (1), 31-55.
- Srivastava, R. K., Greff, K. ve Schmidhuber, J., 2015a, Highway networks, *arXiv preprint arXiv:1505.00387*.
- Srivastava, R. K., Greff, K. ve Schmidhuber, J., 2015b, Training very deep networks, *Advances in neural information processing systems*, 28.
- Steitz, J.-M. O., Saeedan, F. ve Roth, S., 2018, Multi-view x-ray R-CNN, *German Conference on Pattern Recognition*, 153-168.
- Subramani, M., Rajaduari, K., Choudhury, S. D., Topkar, A. ve Ponnusamy, V., 2020, Evaluating One Stage Detector Architecture of Convolutional Neural Network for Threat Object Detection Using X-Ray Baggage Security Imaging, *Revue d'Intelligence Artificielle*, 34 (4), 495-500.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z., 2016, Rethinking the inception architecture for computer vision, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2818-2826.
- Tan, M. ve Le, Q., 2019, Efficientnet: Rethinking model scaling for convolutional neural networks, *International conference on machine learning*, 6105-6114.
- Tianyu, Z., Zhenjiang, M. ve Jianhu, Z., 2018, Combining cnn with hand-crafted features for image classification, *2018 14th IEEE international conference on signal processing (ICSP)*, 554-557.
- Wei, Y. ve Liu, X., 2020, Dangerous goods detection based on transfer learning in X-ray images, *Neural Computing and Applications*, 32 (12), 8711-8724.
- Wikipedia, 26.08.2022, X-ray, <https://en.wikipedia.org/wiki/X-ray>: [26.08.2022].
- Wu, J. ve Liao, S., 2022, Intelligent Detection of Dangerous Goods in Security Inspection Based on Cascade Cross Stage YOLOv3 Model, *Tehnički vjesnik*, 29 (3), 888-895.

- Wu, Y., Xie, F., Yang, J., Cheng, E., Megalooikonomou, V. ve Ling, H., 2012, Computer aided periapical lesion diagnosis using quantized texture analysis, *Medical Imaging 2012: Computer-Aided Diagnosis*, 361-367.
- Wu, Z., Shen, C. ve Van Den Hengel, A., 2019, Wider or deeper: Revisiting the resnet model for visual recognition, *Pattern Recognition*, 90, 119-133.
- Xu, M., Zhang, H. ve Yang, J., 2018, Prohibited item detection in airport X-ray security images via attention mechanism based CNN, *Chinese Conference on Pattern Recognition and Computer Vision (PRCV)*, 429-439.
- Yang, J., Zhao, Z., Zhang, H. ve Shi, Y., 2019, Data augmentation for X-ray prohibited item images using generative adversarial networks, *IEEE Access*, 7, 28894-28902.
- Yao, S.-q., Su, Z.-g., Yang, J.-f. ve Zhang, H.-g., 2021, A prohibited items identification approach based on semantic segmentation, *Optoelectronics Letters*, 17 (4), 247-251.
- Zhang, X., Zhou, X., Lin, M. ve Sun, J., 2018, Shufflenet: An extremely efficient convolutional neural network for mobile devices, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 6848-6856.
- Zhao, C., Zhu, L., Dou, S., Deng, W. ve Wang, L., 2022, Detecting Overlapped Objects in X-Ray Security Imagery by a Label-Aware Mechanism, *IEEE transactions on information forensics and security*, 17, 998-1009.
- Zhou, Z.-H., 2021, Machine learning, Springer Nature, p.
- Zhu, Y. ve Newsam, S., 2017, Densenet for dense flow, *2017 IEEE international conference on image processing (ICIP)*, 790-794.
- Zou, L., Yusuke, T. ve Hitoshi, I., 2018, Dangerous objects detection of X-ray images using convolution neural network, *International Conference on Security with Intelligent Computing and Big-data Services*, 714-728.